

Jari Korpela

**KONEOPPIMISEN HYÖDYNTÄMINEN
KAUPALLISEN LENTOYHTIÖN TOIMINNOISSA**



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2019

TIIVISTELMÄ

Korpela, Jari

Koneoppimisen hyödyntäminen kaupallisen lentoyhtiön toiminnoissa

Jyväskylä: Jyväskylän yliopisto, 2019, 48 s.

Tietojärjestelmätiede, kandidaatintutkielma

Ohjaaja: Makkonen, Pekka

Tämä kandidaatintutkielma on kirjallisuuskatsaus, jonka tarkoituksena on selvittää, miten koneoppimista voitaisiin hyödyntää lentoyhtiön tärkeimmissä toiminnoissa. Tarkoituksena on parantaa tietojärjestelmäasiantuntijoiden ymmärrystä lentoyhtiön toiminnoista ja lentoyhtiön henkilöstön ymmärrystä koneoppimisen menetelmistä ja toimintaperiaatteista.

Tutkielmassa esitetään perusteet valituille lentoyhtiön toiminnoille. Käsitellyt toiminnot ovat: lentolippujen hinnoittelu, työaikojen suunnittelu, myöhästymisten ennustaminen, lentoturvallisuus ja menetelmät sekä lentämisen automaation ratkaisut.

Koneoppimisen toimintaperiaatteiden vuoksi hyödyntämistä tulisi suunnitella toimintoihin, joissa ei käytetä sääntöpohjaisia ratkaisuja. Asiantuntijoiden hyödyntäminen ohjatussa oppimisessa ja heidän kokemuksensa tietojen esikäsitelyssä pitäisi hyödyntää. Ratkaisuissa tulisi koneoppimisen mahdollisuuksilla tukea tavoiteltuja hyötyjä. Myöhästymisten ennustamisessa on saavutettavissa uusia hyötyjä uusilla menetelmillä. Lisäksi simulaattorikoulutuksen ja lennontaltiointijärjestelmien kautta olisi mahdollista saada lentoturvallisuuteen ja lentomenetelmien koulutukseen selviä parannuksia.

Asiasanat: tutkielma, tekoäly, koneoppiminen, lentoyhtiö

ABSTRACT

Korpela, Jari

Koneoppimisen hyödyntäminen kaupallisen lentoyhtiön toiminnoissa

Jyväskylä: University of Jyväskylä, 2019, 48 pp.

Information Systems, Bachelor's degree

Supervisor: Makkonen, Pekka

This bachelor's thesis is a literature review aimed at explaining how machine learning could be utilized in airline key operations. The aim is to improve the awareness of IT systems personnel in airline operations and the understanding of methods and policies of machine learning by airline personnel.

The thesis presents the grounds for selected airline operations. These include pricing of flight tickets, planning of working hours, forecasting delays, flight safety and methods, and automation solutions for flying.

Due to machine learning principles, solutions should be designed for activities that do not use mainly rule-based rules. The use of experts in guided learning and their experience in data pre-processing should be utilized. Solutions should support the potential benefits of machine learning to achieve set aims. New methods of predicting delays can be achieved with machine learning. In addition, it would be possible to obtain clear improvements in flight safety and flight training through simulator training and new air navigation systems.

Keywords: artificial intelligence, machine learning, airline

KUVIOT

KUVIO 1 Lentoyhtiön organisaatio	7
KUVIO 2 Lentoyhtiöteollisuuden arvoketju	8
KUVIO 3 Menetelmien tarkkuudet.....	19
KUVIO 4 Päästöt minimi kustannuksilla ja minimi kulutuksella	24
KUVIO 5 Nopeuden säilytys alkunousussa	32
KUVIO 6 Lennonhallintaohjelmiston kaaviokuva	34
KUVIO 7 Korkeuden säilytys hätätilanteessa	35
KUVIO 8 Tehovipujen käyttö hätätilanteessa	36

TAULUKOT

TAULUKKO 1 Lentoyhtiön liikekulut vuonna 2017.....	9
TAULUKKO 2 Miehistökulut Amerikan isoimmissa lentoyhtiöissä.....	14
TAULUKKO 3 Työaikasunnittelun menetelmät	15
TAULUKKO 4 Ennusteen pituuden vaikutus tarkkuuteen.....	19

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT

TAULUKOT

1	JOHDANTO.....	6
1.1	Tutkimuksen tarkoitus.....	6
1.2	Kaupallisen lentoyhtiön toiminnot	7
1.3	Koneoppiminen.....	9
1.4	Tutkimuksen toteutus	11
2	KONEOPPIMINEN ERI TOIMINNOISSA	12
2.1	Matkustajamäärän ennustaminen ja lentojen hinnoittelu	12
2.2	Työaikojen suunnittelun menetelmät	13
2.3	Koneoppiminen lentojen myöhästymisten ennustamisessa	16
2.3.1	Saapuvan lentoliikenteen myöhästymisen tilan ennustaminen liikennetiedoilla	17
2.3.2	Saapuvan lentoliikenteen myöhästymisen tilan ennustaminen sää- ja liikennetiedoilla	17
2.3.3	Lentoliikenteen myöhästymisen tilan ennustaminen sää- ja liikennetiedoilla RNN-arkkitehtuurin neuroverkolla.....	20
2.3.4	Lentoliikenteen myöhästymisen aikamäärän ennustaminen sää- ja liikennetiedoilla	21
2.3.5	Lentoliikenteen sää- ja liikennetietojen käsittelyn optimointi	22
2.4	Lentoturvallisuuden lisääminen.....	25
3	HYÖDYNTÄMÄTTÖMIÄ KONEOPPIMISEN KYKYJÄ.....	27
3.1	Mukautuva automaatio	27
3.2	Automaattinen tekoälyohjaus.....	29
3.2.1	Nykyisten autopilottien turvallisuusongelmat.....	30
3.2.2	Koneoppimiseen perustuva ohjausjärjestelmä	30
3.2.3	Nousu matkalentokorkeuteen.....	31
3.2.4	Hätätapauksen toimenpiteet	33
3.2.5	Lentoonlähdestä laskeutumiseen	36
3.2.6	Poikkeavat tilanteet.....	37

1 JOHDANTO

Lentoyhtiöiden toiminta on aina ollut perinteistä ja vanhoihin hyviin käytänteisiin perustuvaa. Muutokset tapahtuvat hitaasti. Tekoälyn kehitys on ollut viime aikoina nopeaa, johtuen koneoppimisen kehityksestä. Voidaanko uusia koneoppimisen menetelmiä hyödyntää perinteisissä lentoyhtiöissä? Ollessani lentoyhtiön lentäjänä, en tiennyt yhtään työntekijää, joka tunsikin tekoälyn toimintaperiaatteet. Myöhemmin tietotekniikkaa opiskellessani en ole tavannut yhtään tietotekniikan ammattilaista tai opiskelijaa, joka ymmärtäisi lentoyhtiön toimintaa. Näiden ammattiryhmien yhteisymmärrys on edellytyksenä menetelmien kehittämiseksi ja hyödyntämiseksi. Toivon tutkimuksesta olevan hyötyä lentoyhtiöissä työskenteleville, jotta he ymmärtäisivät paremmin, mitä tekoälyllä voi tehdä. Toisaalta toivon myös, että informaatioteknologian piirissä työskentelevät ymmärtäisivät paremmin lentoyhtiön toimintaa tekoälyn hyödyntämisen kannalta.

1.1 Tutkimuksen tarkoitus

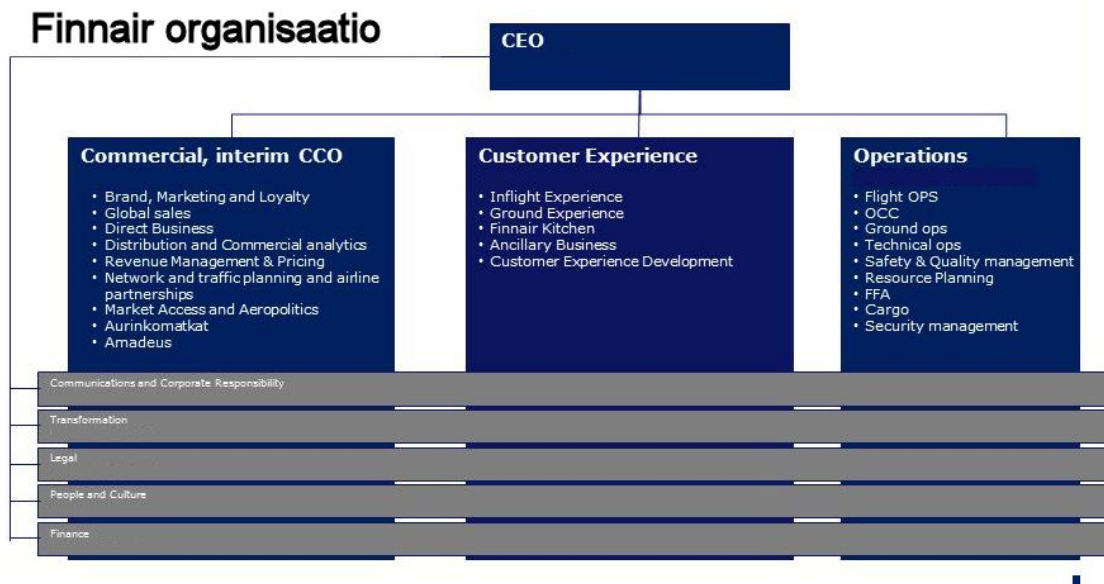
Tässä kandidaatintutkielmassa tutkitaan koneoppimisen hyödyntämistä kaupallisen lentoyhtiön toiminnassa. Tutkielmassa keskityn viime aikoina saavutettujen tekniikoiden ominaisuuksiin, koska tekoälyn kehitys on mahdollistanut monien uusien kykyjen saatavuuden. Hyödyntäminen vaatii taustalla olevan tekniikan sekä lentoyhtiön toimintatapojen ymmärtämistä. Koneoppiminen on tekoälyn toiminnan perusta ja sen avulla tekoälylle luodaan erilaisia kykyjä. Kykyjen hyödyntäminen on operatiivista toimintaa, mutta kykyjen luominen vaatii tutkimusta ja algoritmien kehittämistä. Tämän vuoksi keskityn koneoppimisen käyttöön lentoyhtiön toiminnoissa liittyviin tutkimuksiin. Tutkimuksen tavoitteena on selvittää, miten koneoppimista on tutkittu ja voidaan hyödyntää lentoyhtiöissä. Käytän tutkielmassa pitkää johdantoa, jotta lukija ymmärtäisi paremmin johdannossa käsitellyt ratkaisuja.

Pyrin etsimään kirjallisuudesta lentoyhtiöiden toimintaan liittyviä tutkimuksia, joissa on hyödynnetty koneoppimista. Esittelen hyödynnettävissä olevat

tutkimukset sekä niiden erityispiirteet liittyen suomalaisen toiminnan vaatimuksiin. Lisäksi pohdin mahdollisuuksia löytää vielä hyödyntämättömiä mahdollisuuksia koneoppimisen kykyjen kannalta. Lentoyhtiön tärkeimmissä toiminnoissa voidaan hyödyntää koneoppimista. Nämä toiminnot liittyvät aikatauluihin, koulutukseen ja lentoturvallisuuteen. Sääntöperusteiset tehtävät eivät sovellu koneoppimiselle, kuten työaikojen suunnittelu.

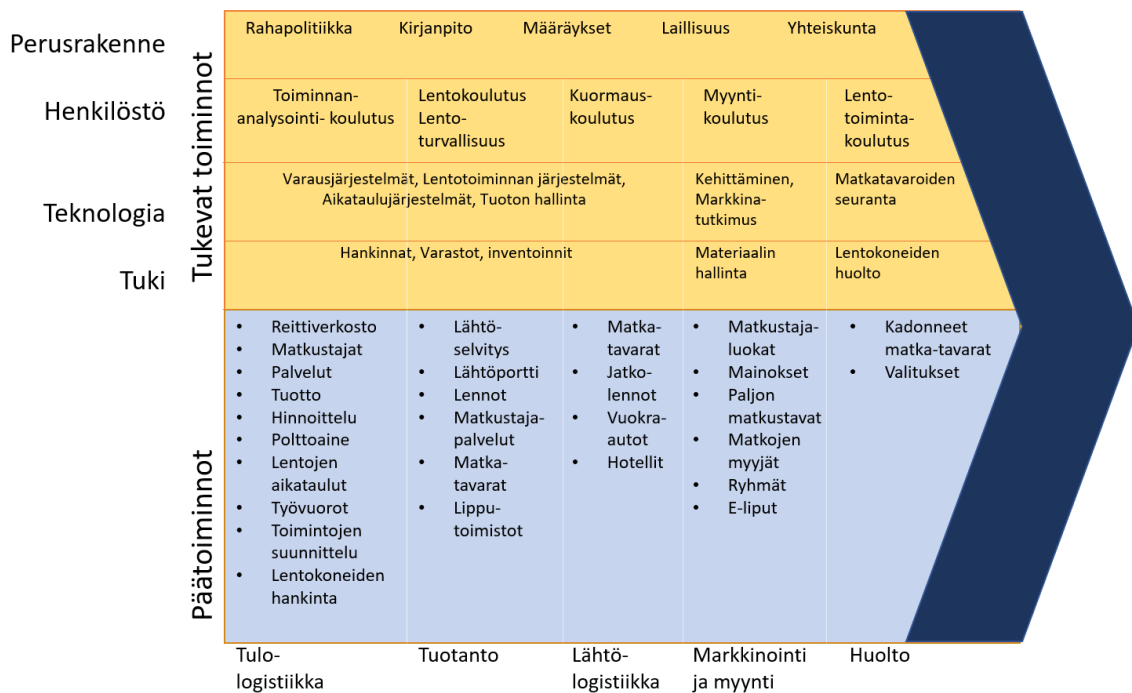
1.2 Kaupallisen lentoyhtiön toiminnot

Pyrin selvittämään koneoppimisen hyödyntämistä jakamalla tutkimukset lentoyhtiön toiminnoittain. Koska lentoyhtiöiden organisaatiot ovat erilaisia ja matriisimaisia, kuten Finnairilla (kuvio 1), toimintojen erittely ei ole yksiselitteistä.



KUVIO 1 Lentoyhtiön organisaatio (Finnair, 2019)

Lentoyhtiön toiminnot erittelen Porterin arvomuodostusprosessin perusteella. Prosessissa (Porter, 1985) organisaation toiminnot jaetaan kahteen osaan: päätoimintoihin ja tukeviin toimintoihin. Päätoiminnoissa ovat tulologistiikka, tuotanto, lähtölogistiikka, markkinointi, myynti sekä huolto. Tukevissa toiminnoissa ovat talous, hallinto, kehitys ja hankinta. Raaka-aineiden tulosta asti tuote kulkee arvoketjussa ja saa lisäarvoa jokaisessa arvoketjun vaiheessa. Arvoketjua voidaan tutkia kokonaisessa teollisuudessa tai vain organisaation yksikössä. Koneoppimisen tuomaa arvoa lentoyhtiölle kuvaa se, paljonko yhteensä saadaan lisää arvoa koneoppimisesta. Lähtökohtana pidän Turban, McLean, ja Wetherbe (2002) kirjassaan esittämää lentoliikenneteollisuuden arvoketjua, jossa lentoyhtiön toiminnot on eritelty arvoketjun mukaisesti (kuvio 2). Näistä ydintoiminnoina tutkielmassa käsitellään matkustajat, tuotto, hinnoittelu, polttoaine, lentojen aikataulut, työvuorot, lennot sekä tukitoimista lentokoulutus ja lentoturvallisuus.



KUVIO 2 Lentoyhtiöteollisuuden arvoketju (Turban ym., 2002)

Näiden toimintojen tärkeyttä perinteisillä lentoyhtiöillä voidaan arvioida esimerkiksi alla olevalla yhdistetyllä taulukolla (taulukko 1). Siinä on koottu Lufthansan (2018) ja Finnairin (2018) vuosikatsauksista toimintojen aiheuttamia kuluja suhteessa liikekuluihin. Lisäksi taulukossa on Franken (2004) julkaisussa mainittu halpalentoyhtiöiden kulujakaumat. Näiden yhtiöiden kustannukset on esitetty vuosikatsauksessa hieman toisella jaolla, koska heidän toimintansa on erityyppistä. Tuottojen ja kustannusten perusteella tutkimusten hauissa on painotettu arvoketjun alueista lentämiseen, polttoaineeseen, aikatauluihin, työvuoroihin, lentokoulutukseen ja lentoturvallisuuteen liittyviä tutkimuksia.

TAULUKKO 1 Lentoyhtiön liikekulut vuonna 2017 (mukaellen Finnair, 2018 ja Lufthansa, 2018 ja Franke, 2004)

Toiminto	Finnair		Lufthansa Group		Halpa-lentoyhtiöt
	Milj. €	%	Milj. €	%	%
Henkilöstökulut	423,3	17,5	8172	23,5	33
Polttoainekulut	472,2	19,5	5232	15,0	
Muut vuokrat	157,9	6,5	6357	18,3	15
Lentokaluston huoltokulut	165,7	6,9	884	2,5	13
Liikennöimismaksut	266,5	10,8			9
Maaselvitys- ja catering-kulut	252,2	10,2	3267	9,4	12
Arvonalentumiset	129,2	5,3	2052	5,9	

On hyvä muistaa, että lisäarvoa pitää tarkastella muutenkin, kuin euromääräisenä vaikutuksena. Esimerkiksi säästöt lentoturvallisuudessa voivat aiheuttaa lentoyhtiölle asiakkaiden menetyksiä johtuen negatiivisista uutisista. Pahimmillaan lento-onnettomuus yhtiössä aiheuttaa konkurssin.

Eri toiminnoissa on paljon asiantuntija- ja asiakaspalvelutehtäviä. Moninaiset tehtävät ja työkuultuuri vaativat perehtyneisyyttä vakiintuneisiin käytänteisiin. Viranomaisvaatimuksista johtuen nämä työtehtävät ovat tarkasti määriteltäviä yhtiön kirjallisissa toimintaohjeissa. Kuitenkaan kaikkea ei voida kirjoittaa ohjekirjoihin, joten osa hyvistä käytännöistä on hiljaista tietoa, jota kutsutaan ilmailualalla termillä *airmanship*. Vaikka lentoyhtiön toimintoja säädellään monilla säännöillä ja määräyksillä, asiantuntijoiden kokemuksella on suuri merkitys toiminnalle. Perinteiset sääntöpohjaiset ohjelmat sopivat sääntöjen ja määräysten käsittelyyn, mutta tuon hiljaisen tiedon käsittely sopii hyvin koneoppimiselle.

1.3 Koneoppiminen

Kuinka kokemusta voidaan opettaa tietokoneelle? Voisiko tekoäly oppia ja kuinka tekoäly toimii? Tekoäly on tiedon analysointia. Viime aikoina suurten tietomäärien saatavuus ja laskentakapasiteetin kasvu on mahdollistanut tekoälyn kehityksen. Ensimmäiset maininnat tai viittaukset tekoälyyn ovat jo yli 60 vuotta vanhoja. John McCarthy (1955) määritteli, että tekoälyn tarkoituksena on kehittää koneita, jotka käyttäytyvät, kuten ne olisivat älykkäitä. Vuorovaikutus ihmisen kanssa ja kognitiiviset kyvyt, kuten puheen, tekstin sekä kuvan sisällön ymmärtäminen, tarvitsevat tietokoneelta paljon laskentakykyä ja nopeutta. Koneoppiminen mahdollistaa kognitiiviset kyvyt eli puheen, tekstin sekä kuvan

tulkittamisen. Tekoälyn kyvykkyyksiä on helppo verrata ihmisen aisteihin ja toimintoihin. Kuvantunnistus vastaa näköä. Puheen muuttaminen tekstiksi vastaa kuuloa, tekstin muuttaminen puheeksi vastaa puhumista, tekstianalyysi vastaa lukemista ja ymmärtämistä. Tiedonkäsittely vastaa muistia ja koneoppiminen päättelyä ja oppimista. Tekoälyä ovat kehittäneet useat yhtiöt, kuten Amazon, Facebook, Google, IBM ja Microsoft. Eri yhtiöt ovat erikoistuneet hieman eri kykyihin ja standardia ei ole monimuotoiselle tekniikalle.

Tekoälyn käyttöä on helpotettu rajapinnoilla, jotka mahdollistavat erilaisten kykyjen käytön valmiina palveluina. IBM Watson tekoäly perustuu IBM Cloudin tarjoamiin palveluihin (SaaS). Palvelu osaa aina tietyn kyvykkyyden esimerkiksi tekstin muuttamisen puheeksi. Muita esimerkkejä palveluista ovat puhe tekstiksi, mielialan analyysi, kuvantunnistus, keskustelu, luonnollisen kielen luokittelu ja luonnollisen kielen ymmärtäminen. (IBM Watson, 2019.)

Koneoppimisen käyttö kuvioiden tunnistamisessa, luonnollisessa kielenkäsittelyssä ja laskennallisissa menetelmissä perustuu algoritmeihin, jotka oppivat syötetiedosta ja tekevät niistä päätelmiä tai ennusteita. Kaikkia erilaisia tilanteita varten ei ole olemassa erillisiä sääntöjä, vaan oppiminen perustuu koneen tekemään algoritmiin, joka arvioi lähtötietojen perusteella syötetietoja vastaavan tuloksen. Tekoäly oppii tekemään älykkäitä päätöksiä, jotka perustuvat historialliseen tilastotietoon eikä ohjelmointiin. Tekoälyä luodaan koneoppimisella. Riittäväällä määrällä opetustapauksia löytyy algoritmi, joka antaa myös uusilla tapauksilla todennäköisesti lähes oikean vastauksen. Tällöin ei tarvita sääntöpohjaisia ohjelmia vaan käytetään tilastotiedettä ja uusia laskentatapoja. (Weibo ym., 2017.)

Koneoppimista on kolmea perustyyppiä: ohjattu, ohjaamaton ja vahvistettu. Ohjatussa oppimisessa opetustiedoissa annetaan mukana haluttu tulos. Ohjaamattomassa oppimisessa ei anneta haluttua tulosta, vaan kone esittää riippuvuuksia, suhteita ja samankaltaisuuksia. Vahvistetussa oppimisessa haluttu tulos algoritmille saadaan ympäristön antamasta palautteesta. Käytetyt algoritmit valitaan perustyyppin, syötetietojen ja halutun tuloksen mukaan. Syötetiedot voivat olla esimerkiksi jatkuvia tietoja tai epäjatkuvia tietoja. (Bell, 2015.)

Koneoppimisen uusimmat laskennat perustuvat neuroverkkoihin, joiden perusrakenteeseen kuuluvat syötekerros, piilokerrokset sekä ulostulokerros. Syötekerrokseen tuodaan lähtöarvot eri tiedoista. Piilokerroksissa tulosten yhdistely ja automaattinen painotus säätelevät laskentaa, jotta saataisiin ulostulokerrokseen halutut tulokset. Käytettyjä algoritmeja ovat logistinen regressio, neuroverkot, päätöspuut, k:n lähimmän naapurin menetelmä, tukiverkkokone, Naiivi Bayes -luokittelija, Diskriminaattianalyysi, satunnainen metsä, k-means-klusterointi, kernel-tiheysarvio, gaussian-sekoitusmalli. (Bell, 2015.)

Neuroverkoista on kehitetty syväoppivia neuroverkkoja (DNN). Syväoppiminen koostuu yleensä hierarkkisesta arkkitehtuurista, jossa on useita kerroksia erillisiä neuroverkkoja. Jokainen kerros tekee oman epälineaarisen tietojenkäsittelynsä. Syväoppimisessa käytetään erilaisia verkkoarkkitehtuureja verkon sisällä ja näin voidaan käsitellä monimutkaisempia kokonaisuuksia. Syötetiedot voidaan luokitella ennen käsittelyä ja näin saadaan monipuolisempia tulkintoja

tiedosta. Tiedon käsittely voi olla normaalista neuroverkosta poiketen palauttava eli saadut tulokset palautetaan tietovirran alkuun (Backpropagation). Palautetut tulokset vaikuttavat uudelleen tehtävään laskentaan. Monimutkaisemmat mallit vaativat kuitenkin paljon laskentakapasiteettia oppimisvaiheessa. (Weibo ym., 2017.)

Lopputulokseen vaikuttavat myös lähtötiedon määrä, monipuolisuus ja aukottomuus. Tiedonlouhintaan menee Davis ja Clarkin (2011) mukaan 10–20 % ajasta ja tiedon esikäsittelyyn 50 % ajasta. Näin jopa 70 % ajasta käytetään muuhun kuin algoritmin opettamiseen. Esikäsittelyssä asiantuntijoiden ja tiedon sisällön ymmärtäminen on erittäin tärkeä osa koneoppimista. Algoritmin opetukseen ja laskentaan voi mennä päiväkausia, mutta valmis malli toteuttaa opitun asian silmänräpäyksessä.

1.4 Tutkimuksen toteutus

Tämän kandidaatintutkielman menetelmänä on kirjallisuuskatsaus. Aluksi määrittelen ja rajaan lentoyhtiön toiminnot sekä koneoppimisen osa-alueet, joita käsitellään tutkimuksessa. Johdannossa esittelen tutkimuksen tarkoitusta ja päämääriä sekä määrittelen käytettyjä termejä sekä tehtyjä valintoja. Perustelen, mitkä ovat lentoyhtiön tärkeimmät toiminnot, joita käsittelen. Sen jälkeen esittelen koneoppimisen erilaisia käyttötapoja. Teksteissä on useasti luontevampaa puhua tekoälystä, vaikka tekoälyn toiminta perustuu koneoppimiseen.

Kirjallisuuskatsauksen haut on rajattu informaatioteknologiassa vakiintuneisiin tietokantoihin ja toteutettu tietokannoista: IEEE Xplore Digital Library, ACM Digital library. Monitieteisistä tietokannoista on tehty hakuja tietokannoista Scopus, Web of Science ja Google Scholar. Tekoälyn ja koneoppimisen viimeaikaisen nopean kehityksen vuoksi rajasin haut vuosiin 2011–2019. Pysin valitsemaan Julkaisufoorumin suosituksia, mutta lentoyhtiöitä käsittelevien tutkimusten rajallisuudesta johtuen valitsin myös Google Scholarin mukaan paljon viitattuja dokumentteja tai ammattikäyttöön tarkoitettuja tekoälyn internetkäyttöohjeita. Käytettyjä hakusanoja olivat: artificial, airline, intelligence, machine learning, deep learning, cognitive, artificial intelligence, pilot, crew, neural, review ja survey. Näistä löytyneistä tutkimuksista valitsin käytettyjä parhaita lähdeviitteitä lisähakuihin. Suomenkielisiä hakusanoja en käyttänyt.

Seuraavissa luvuissa tutkin, mitä tutkimuksia on jo tehty näihin lentoyhtiön työtehtäviin liittyen. Pysin löytämään tutkimuksissa tehdyille ratkaisuille perusteita sekä toisenlaisia ratkaisumahdollisuuksia. Toisena tarkastelun näkökulmana on koneoppimisen hyödyntämättömät tutkimustulokset. Hyödyntämismahdollisuuksia voisi etsiä muistakin yhtiöistä kuin lentoyhtiöistä, mutta se laajentaisi hakuja kohtuuttomasti. Yhteenvedossa kootaan ne soveltamismahdollisuudet, jotka olisivat hyödynnettävissä lentoyhtiöiden toiminnassa sekä toisenlaiset lähestymistavat tutkimusten aiheeseen.

2 KONEOPPIMINEN ERI TOIMINNOISSA

Tässä luvussa esittelen jo tutkittuja koneoppimiseen perustuvia ratkaisuja lentoyhtiön toimintoihin liittyen. Koneoppimisen kyvykkyudet ovat kehittyneet vasta lähivuosina, joten tutkimuksia ei ole tehty kaikkiin toimintoihin liittyen. Tutkielmani keskittyy vain tehtyihin tutkimuksiin, vaikka kyvykkyuksiin liittyviä sovelluksia on voitu ottaa käyttöön ilman aiheesta julkaistua tutkimusta. Ensin esittelen lentoyhtiön tuloja tekevän lipunmyynnin, minkä jälkeen esittelen kuluja aiheuttavat toiminnot.

2.1 Matkustajamäärän ennustaminen ja lentojen hinnoittelu

Lipun myynnissä tutkimukset voidaan jakaa kahteen osaan. Ensimmäinen osa käsittelee kysynnän määrittelyä ja toinen hintasyrjintää. Hintasyrjintä tarkoittaa valmiutta ja halukkuutta maksaa samasta lipuista erilaisia hintoja. Nämä ovat lentoyhtiölle tärkeitä tietoja, koska lipputulot ovat käytännössä ainoa tulolähde, jos yhtiöllä ei ole rahtilentotoimintaa. Kysyntään liittyy myös kapasiteetin mahdollisimman tehokas käyttö eli tarkoitus on myydä lentokone mahdollisimman täyteen hyvällä hinnalla ja huomioida samalla, että osa matkustajista ei ilmestykään varatulle lennolle. Jos kysyntä on oletettua vähäisempää, voidaan lento lentää pienemmällä koneella ja kuluilla. Samalla, kun lentoyhtiö optimoi lippujensa hintoja, matkustajat yrittävät myös saada lippunsa mahdollisimman halvalla oikeaan aikaan oikeasta yhtiöstä.

Tässä tutkielmassa keskityn lentoyhtiön tekemään hinnoitteluun. Asiakkaan tekemät valinnat liittyvät kiinteästi yhtiön myyntistrategiaan. Lentoyhtiön on tiedostettava, että asiakkaat hyödyntävät lippujen hintojen sekä ostoajankohdan optimoivia järjestelmiä. Näistä on koottuna useita koneoppimista hyödyntäviä tutkimuksia (Abdella, Zaki, Shuaib & Khan, 2019).

Lentoyhtiön hinnoittelustrategiat voivat perustua pitkän tavoitteen hinnoitteluun, tuotto hinnoitteluun tai dynaamiseen hinnoitteluun (Narangajavana, Garrigos-Simon, García & Forgas-Coll, 2014). Malighetti, Paleari ja Redondin (2009) mukaan dynaaminen hinnoittelu on monipuolisin ja vaativin tapa, joka ottaa huomioon sisäiset tekijät, ulkoiset tekijät, kilpailutilanteen ja strategiset asiakkaat sekä hintavaihtelun. Sisäisiä tekijöitä ovat hintahistoria, ostopäivä, lähtöpäivä, kausi, lomat, tarjonta, lippuluokka, vapaat paikat, markkinatilanne ja lennon pituus. Ulkoisia tekijöitä ovat tapahtumat, uhkat, lakot, juhlat, konferenssit, säätilanteet ja taloustilasteet. Dynaaminen hinnoittelu on vaativa ja samalla sopivin koneoppimiselle. Dynaaminen hinnoittelu sopii monen syötetiedon käsittelyyn ja useissa tutkimuksissa todetaankin syötetietojen olevan liian suppeita ja ulkoisten tekijöiden lisäämisestä saataisiin paljon parempia tuloksia. (Malighetti, Paleari & Redondi, 2009.)

Ulkopuolisten ja sisäisten tekijöiden vaikutusta kysynnän ennustamiseen tutkiessaan Yuan, Xu ja Yang (2014) käyttivät kysynnän ennustamiseen asiakkaan soittoja, internethakua sekä lippuhintojen vaihtelun historiatietoja neljältä vuodelta. Neuroverkko ja tukivektoriregressiot antoivat heille tuloksen, että ulkopuoliset tekijät mahdollistivat ennustamaan pienimmän keskimääräisen virheen, joka oli 4,66 %.

Kun myöhemmin tutkittiin kysynnän ennustamista (Yang ja Liu, 2018) Randon Forest -malli ennusti matkustajamäärän 4,18 % keskimääräisellä virheellä (MAPE). Tukivektoriregressio (SVR) ja Neuroverkko-metodit eivät tuolloin kyenneet yhtä pieneen virheeseen. Kysynnän tutkimuksissa vuosilla 2014 – 2017 on koneoppimista käytetty kolmessa tutkimuksessa. Tekniikat olivat klusterit, neuroverkot ja Bayesian verkko. Hintasyrjintään ei ole käytetty koneoppimista, vaikka se olisi siihen sopiva tekniikka.

Hintasyrjinnässä on tärkeää profiloida asiakas. Profiloinnissa voidaan käyttää esimerkiksi rekisteröintitietoja tai eväsetietoja. Constantinides ja Diercksin (2014) tutkimuksen mukaan profilointi tiedot muualta kuin evästeistä olivat parempia. Sosiaalisen median ja internetsivujen hyödyntäminen lisää ennustettavuutta. Sosiaalisen median analyysiin on jo olemassa valmiita rajapintoja käytettäväksi (IBM, 2019). Syväoppiminen mahdollistaisi näiden tietojen käytön reaaliaikaisesti koko internetistä. Näin voisi päivittää tapahtumien, blogien ja uutisten tietoja reaaliaikaisesti. Abdella ym. (2019) mukaan tällaisia sosiaalisen median hyödyntämisä ei löytynyt mistään tutkimuksista.

Mikäli lentoyhtiö sekä asiakas saavat käyttöönsä tekoälyä hyödyntävän ratkaisun, lentojen hinnoittelu saattaa siirtyä tekoälyjen väliseksi kaupaksi. Tällöin kaupankäynnissä korostuu tiedon saatavuus sekä omien tietojen peittäminen tai muuttaminen. Lippujen hinnoittelussa lentoyhtiöllä on etuna laajat omat tietovarastot. Dynaaminen hinnoittelu on tehokasta ja lentoyhtiöllä on siihen hyvät mahdollisuudet omien tietojensa avulla. Uudet tekniikat mahdollistavat automaattisen ulkoisen tiedon käytön syötetietoina. Lentoyhtiön tulojen hankkiminen tulee tulevaisuudessa olemaan vahvasti sidoksissa tietotekniikan ja tiedon hallintaan. Tulojen lisäksi on hallittava myös menot. Seuraavissa luvuissa käsitellän lentoyhtiön toimialoja, joissa koneoppimista voidaan hyödyntää menojen vähentämiseksi.

2.2 Työaikojen suunnittelun menetelmät

Miehistön kustannukset ovat lentoyhtiön toiseksi suurin kustannus polttoainekustannusten jälkeen. Vuonna 1991 American Airlines käytti 1,3 miljoonaa dollaria miehistön menoihin (Gopalakrishnan ve Johnson, 2005). Lentoyhtiöiden miehistön työaikasunnittelu vaikuttaa merkittävästi kustannuksiin. Tämän luvun tiedot perustuvat kirjallisuuskatsaukseen (Deveci & Demirel, 2015), jossa on vuoteen 2015 mennessä käytettyjä menetelmiä. Luvun lopuksi esitän muutamia uudempia tutkimuksia ja niissä käytettyjä menetelmiä.

Työvuorojen suunnittelu on jaettu kolmeen vaiheeseen: lentoaikataulut, ilma-alusten aikataulut ja miehistön aikataulut. Lentokoneiden ja miehistöjen aikataulujen suunnittelu on jaettu kahteen alaluokkaan. Lentokoneiden suunnittelussa ensin määritetään käytettävä konetyyppi ja sitten yksittäisten lentokoneiden reititykset. Miehistöjen työaikasunnittelu koostetaan aikatauluista tehtäviin lentojen sarjoihin (pairing), joihin liitetään miehistöt (rostering). Nämä suunnitelmat ovat erillisiä, mutta vaativat optimointia kustannuksiltaan edullisimman ja laillisen ratkaisun löytämiseksi. (Anbil, Tanga & Johnson, 1992.)

Lentosarja alkaa ja päättyy kotikentälle ja kestää yleensä kolme tai neljä päivää. Miehistön jäsen tekee yleensä neljä tai viisi lentosarjaa kuukaudessa. Miehistön lentosarjoja rajoittavat ilmailuviranomaisen säännöt ja turvallisuusmääräykset, työaikalait ja miehistön työehtosopimukset. Lentosarjat kattavat kaikki yhtiön lennot ja tarkoituksena on minimoida kustannukset. Alla olevassa taulukossa on esitetty eri lentoyhtiöiden miehistön kustannuksia (Bazargan, 2010).

TAULUKKO 2 Miehistökulut Amerikan isoimmista lentoyhtiöissä (Bazargan, 2010)

Lentoyhtiö	Miehistön määrä	Miehistökulut	Miehistökulut vs kokonaiskulut
Alaska	1,455	180,845,000	5.57 %
AirTran	1,632	157,383,851	6.00 %
American	11,166	1,152,808,000	4.48 %
Continental	4,867	623,767,000	4.05 %
Delta	12,299	802,811,000	3.84 %
Southwest	5,915	965,329,000	9.13 %
United	6,478	757,020,000	3.44 %
US Airways	5,275	482,044,882	3.39 %

Pelkkien kustannusten lisäksi aikataulujen toimivuutta voidaan mitata miehistön väsymisen ennakoinnilla. Miehistön väsymykseen vaikuttavat pääasiassa kaksi tekijää: unen menetys ja epäsäännöllinen nukkuminen. Vaikka viranomaisen on antanut työajan rajoituksia, ei ole mitään erityistä sääntöä unen menetyksen ja epäsäännöllisten työrytmien arvioimiseksi. Epäsäännöllinen uni vaikuttaa unen rytmeihin, mikä johtaa väsymykseen. (Gander, Rosekind, & Gregory, 1998.)

Koska lentotoiminta (lentokone ja miehistö) on lentoyhtiön kallein toiminto, näiden kahden kohteen aikataulut ovat lentoyhtiöiden kannalta ratkaisevan tärkeitä. Lentoyhtiöt ja tutkijat ovat kehittäneet erilaisia optimointitekniikoita aikataulujen suunnitteluun. Jo vuonna 1993 todettiin, että näitä menetelmiä on kehitetty 40 vuoden ajan. Tavoitteena on minimoida miehistön kustannukset ja täyttää lentoyhtiöiden sääntöjen ja viranomaisten asettamat monet rajoitukset. (Hoffman ja Padberg, 1993.)

Kirjallisuudessa on ehdotettu monia optimointimenetelmiä miehistön aikataulutussongelman ratkaisemiseksi. Alla olevassa taulukossa (taulukko 3) on kooste käytetyistä menetelmistä.

TAULUKKO 3 Työaikasunnittelun menetelmät

Metodi	Tyyppi	Tutkimuksia
Set partitioning	Exact methods	36
Set covering	Exact methods	18
Mixed or integer Programming	Exact methods	24
LP relaxation	Exact methods	13
Linear programming (LP)	Exact methods	5
Branch-and-price	Exact methods	6
Branch-and-bound	Exact methods	4
Branch-and-cut	Exact methods	2
Shortest path problem	Exact methods	13
Tree search algorithm	Exact methods	3
Column generation	Other methods	40
Benders decomposition	Other methods	6
Dantzig-Wolfe Decomposition	Other methods	1
Carmen systems	Other methods	5
Nonlinear integer programming	Nonlinear	2
Stochastic programming	Stochastic	4
Genetic algorithm	Population-based metaheuristics	11
Ant colony optimization	Population-based metaheuristics	2
Tabu search algorithm	Single solution-based Metaheuristics	2
Simulated annealing	Single solution-based Metaheuristics	1
Local search algorithm	Single solution-based Metaheuristics	1
Muut menetelmät	-	34

Vuoden 2015 jälkeenkään ei koneoppimista oltu käytetty lentoliikenteen työaikojen suunnittelussa. Lähimpänä koneoppivia ratkaisuja oli sumean logiikan (fuzzy-logic) ratkaisu rautatieyhtiöiden työaikasunnittelussa (Khmeleva, Hopgood, Tipi, & Shahidan, 2018). Rautatieyhtiöiden ongelmat ovat samankaltaisia lentoliikenteen miehistösuunnittelun kanssa laajojen yhteysverkkojen ja runsaiden sääntöjen vuoksi. Yhtiönä oli Iso-Britannian DB-Schenker Rail -yhtiö. Miehistökustannusten osuus oli jopa 20–25 % kokonaiskustannuksista. Sumealla logiikalla saavutettiin jopa 10 % säästöt kustannuksissa. Pelkkä suunnittelu ei käytännön elämässä riitä, koska monet häiriöt vaativat tehdyn suunnitelman muuttamista.

Suunnitelman muutos kuitenkin aiheuttaa muille miehistöille työmäärän lisääntymistä, lepoaikojen vähenemistä ja mahdollisesti turvallisuussääntöjen rikkomuksia. Sääntöjä rikkomatta olisi suunniteltava uudelleen, kuinka mahdollisissa häiriöissä miehistön käytössä selvittäisiin mahdollisimman pienillä kuluilla. Zhang, Ma, Yang ja Chen (2018) tutkivat Tabu Search -algoritmillä myöhästymisten ja miehistön käytön muutoksia häiriötapauksissa. Suunniteltu malli tuotti hyviä tuloksia, luotettavasti ja laskennallisesti tehokkaasti. Mallin heikkoutena oli kuitenkin, että oletuksena kaikki miehistöt voivat lentää kaikkia

tarvittavia konetyyppejä. Toinen tutkimus (Chen & Chou, 2017), jossa tutkittiin tehdyn miehistösuunnitelman muutosta hallinnolliset ja turvallisuusmääräykset huomioiden, tehtiin Pareto-metodilla. Menetelmä tuotti muutaman hyväksyttävän mallin päätöksentekoa varten.

Työvuorojen suunnittelu ja poikkeamien korjaus perustuu moniin sääntöihin ja on näin parempi perinteisille sääntöpohjaisille ratkaisulle. Tutkimuksissaan koneoppimista ei oltu käytetty. Koneoppimista voisi käyttää luonnollisen kielen ymmärtämiseen liittyen miehistöille tehtyjen työvuorojen vaihdoissa. Työntekijöillä on usein tarvetta henkilökohtaisista syistä johtuen vaihtaa keskenään työvuoroja. Työntekijän olisi helppo kuvata sanallisesti toiveensa vaihtotarpeesta. Toiveeseen voisi etsiä lailliset vaihtomahdollisuudet muista vaihtotoiveista ilman monimutkaista rosterointi-laskentaa. Poikkeamat suunnitelmasta aiheuttavat monimutkaisia työaikojen uudelleen järjestelyjä. Näiden poikkeamien ennustamiseen ja ennakointiin voisi käyttää koneoppimista. Jotkin poikkeamat toistuvat aikataulujen mukaisesti, kuten seuraavassa luvussa kerrotaan. Myöhästymisten analysoinnilla voitaisiin vähentää myöhästymisiä sekä ennakoida niitä haittojen minimoimiseksi.

2.3 Koneoppiminen lentojen myöhästymisten ennustamisessa

Myöhästymisistä aiheutuu ylimääräisten miehistökulujen lisäksi lentokentän käyttökuluja sekä jatkolentojen menetyksiä. Ne aiheuttavat matkustajille harmia ja heikentävät lentoyhtiön mainetta. Koneoppimisella on hyvät mahdollisuudet tapahtumien ennustamiseen, vaikka kaikki tapahtumat eivät olekaan ennustettavissa.

Harveyn (2016) mukaan Amerikan kotimaan lennoista myöhästyi vuonna 2016 noin 20 %. Tämä vastaa muissakin tutkimuksissa olleita lukuja. Myöhästymisille on monia syitä: liian lyhyet kääntoaajat, tekniset syyt, maapalvelut, lentokentän toiminnot, ruuhkainen ilmatila ja sää. Säästä johtuvia myöhästymisiä raportoitiin olevan 36–30 % myöhästymisistä. (Harvey, 2016.)

Sää vaikuttaa monella tavalla muihin myöhästymisen syihin. Sää reitillä ja lähtö- tai määräkentällä aiheuttavat myöhästymisiä tuloajoissa sekä rullausaikojen pidentymisinä. Lumisateet aiheuttavat kiitotien käytölle rajoitteita sekä lentokoneen jäätyminenestokäsittelyjen lisääntymisenä. Sään vaikutus voi vaihdella paljon alueellisesti. Myöhästymisen lisäksi tulisi ennustaa lentoaikojen pidentymisiä ruuhkasta tai säästä johtuen. Pidentynyt lentoaika on tärkeä tieto lennon turvalliselle ja taloudelliselle suunnittelulle. Aikataulusuunnittelussa tehdyt lentojen sarjat kertaavat myöhästymistä, jos niihin ei voida reagoida ajoissa.

Seuraavissa alaluvuissa esittelen koneoppimista hyödyntäviä tutkimuksia. Niistä löytyvät piirteet ovat hyödynnettävissä tulevilla tutkimuksilla. Koneoppimisen käyttö myös osoittautuu hyväksi ennustajaksi, jos tutkimus on hyvin toteutettu. Tutkimuksissa ennustettiin, että tapahtuuko myöhästymisen vai ei. Joissain tutkimuksissa pyrittiin lisäksi ennustamaan myöhästymisen aikamäärää. Ennustavina tekijöinä on käytetty aikatauluja sekä säätilaa.

2.3.1 Saapuvan lentoliikenteen myöhästymisen tilan ennustaminen liikennetiedoilla

Tässä tutkimuksessa käytettiin syötetietoina vain aikataulutietoja ja toteutuneiden lentojen tietoja. Pamplona, Weigang, Barros, Shiguemori ja Alves (2018) tutkivat lentoliikenteen myöhästymisen ennustamista käyttämälle Sao Paolon ja Rio de Janeiron välisen lentoliikenteen tietoja. Tutkittuna ajanjaksona oli vuoden 2017 tammikuu, jolloin lennettiin 1560 lentoa. Tutkimuksessa päädyttiin luokittelun tekemiseen käyttäen Random Search -tekniikkaa aiemmin Bergstra ja Bergio (2012) tekemän tutkimuksen perusteella.

Tutkimuksessa todetaan, että Euroopan liikenteen myöhästymisistä yli puolet johtuu lentoyhtiöistä. Toiseksi suurin syy Euroopassa on sanottu olevan lentoliikenteen ohjaus- ja hallintajärjestelmät. Sääolot ovat syynä 16 % myöhästymisistä. Myöhästymisiä ennustettiin vain tapahtumina eikä niiden ajallisina määrinä. Huolimatta lyhyestä aikavälistä sekä vähäisestä määrästä lentoja he pystyivät ennustamaan myöhästymisiä yli 90 % tarkkuudella. Verrattuna muihin tutkimuksiin käytetty malli osoitti, että viikonpäivällä, lentoyhtiöllä, tuloajalla ja lähtöajalla voidaan ennustaa lennon myöhästymistä. (Pamplona ym., 2018.)

Pelkkien aikataulutietojen perusteella ennustaminen voi olla hyödyllistä. Tulos voi osoittaa, että suunniteltua aikataulua on ollut mahdoton käytännössä toteuttaa. Toteutuneissa lennoissa voi olla kyseisinä aikoina ruuhkaa maassa tai ilmassa johtuen suunniteltujen lentojen liian suuresta määrästä. Tällainen säännönmukainen myöhästymisen ilman ulkopuolista syytä pitäisi pystyä korjaamaan tai ainakin pystyä minimoimaan haittoja. Mielenkiintoista oli, että säätiedot jätettiin syötetiedoista pois Euroopan tilastojen perusteella. Tutkimus kuitenkin toteutettiin Brasilian liikennetiedoilla erilaisessa toimintaympäristössä. Seuraavissa tutkimuksissa on huomioitu myös sään vaikutus.

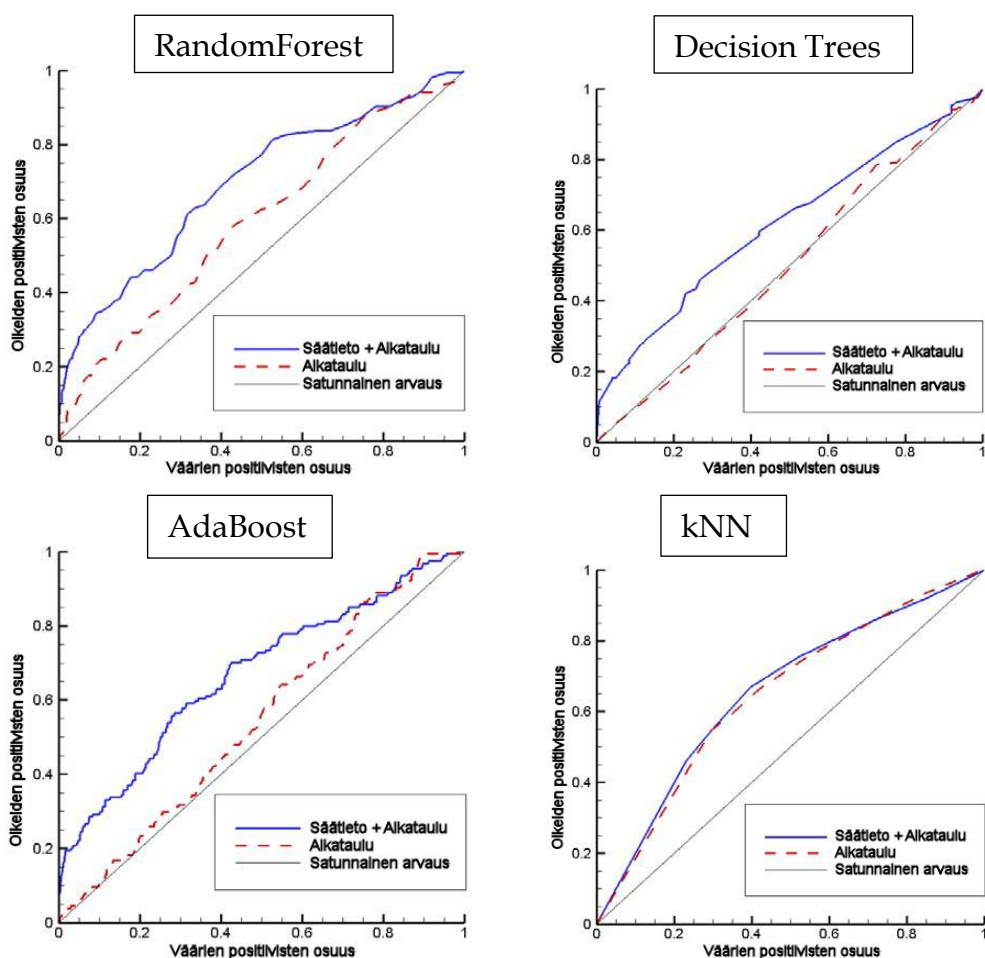
2.3.2 Saapuvan lentoliikenteen myöhästymisen tilan ennustaminen sää- ja liikennetiedoilla

Tässä alaluvussa kerron tutkimuksesta (Choi, Kim, Briceno & Mavris, 2016), jossa pyrittiin ennustamaan myöhästymisiä myös säätietoihin perustuen. Heidän tutkimuksessaan ennustettiin, myöhästyykö saapuva lento vai ei, mutta myöhästymisen aikamäärää ei ennustettu. Syötetietoina he käyttivät sekä lähtö- että määräkentän säätietoja ja sääennusteita. Käsitellyt tiedot olivat Amerikan liikenneviraston tilastotietoja vuosilta 2005–2015 sekä lisäksi lentokentän sääilmoituksen tietoja. Säätiedot kerättiin NOAA:n tietokannoista ja ne muutettiin lukuarvoiksi ja normalisoitiin. Näihin tietoihin yhdistettiin lentojen aikataulutiedot (Choi ym., 2016).

Myöhästymistapahtumat eivät ole tasapainossa, koska myöhästymisiä oli noin viidesosa tiedoista. Pienempään myöhästyvien lentojen luokkaan tulisi pienempi todennäköisyys luonnostaan, joten ennustusmenetelmien toimivuuden vuoksi myöhästyvien luokkaa pitää kasvattaa samankokoiseksi aikataulussa

olevien lentojen kanssa. Tasapainotuksessa käytettiin SMOTE-tekniikkaa kasvatamaan pienemmän luokan esiintymiä. SMOTE-tekniikalla on saatu muita tasapainotuksen menetelmiä parempia tuloksia (Chawla, Bowyer, Hall & Kegelmeyer, 2002). Tekniikkaa käytettiin sekä opetuksen että ennustamisen tietojen esikäsittelyyn.

Luokitteluun Choi ym. (2016) käyttivät neljää menetelmää: Decision Trees, Random Forest, AdaBoost ja K-Nearest-Neighbors (kuvio 3). Kuvion x-akseli kuvaa väärin positiivisten tulosten osuutta kaikista positiivisista tapauksista. Kuvion y-akseli kuvaa oikeiden positiivisten tulosten osuutta kaikista positiivisista tapauksista. Ennusteiden arviointiin käytettiin 10-fold Cross - ja Receiver Operating Characteristic Curve -menetelmiä. Parhaan ennusteen tarkkuuden (83,4 %) he saivat opetusvaiheessa Random Forest -menetelmällä ja käyttämällä SMOTE-tasapainotustekniikkaa. Menetelmän valinnan merkityksen huomaa vertailemalla menetelmien tarkkuuksia erilaisilla valituilla lähtötiedoilla. Random Forest -menetelmässä säätiedot lisäävät ennusteen tarkkuutta. Decision Trees -menetelmässä sekä AdaBoost -menetelmässä pelkällä aikataulutiedoilla ei ole isoa merkitystä tarkkuuteen. Toisaalta taas kNN-menetelmä antaa saman tarkkuuden (82,4 %) pelkällä aikataulutiedolla verrattuna yhdistettyyn sää- ja aikataulutietoon (Choi ym., 2016).



KUVIO 3 (ROC) Menetelmien toimintaominaiskäyrät (Choi ym., 2016)

Tärkeintä on, että kuinka hyvin opetetut mallit ennustavat uudella aineistolla myöhästymisiä. Mallit eivät kyenneet uudella tiedolla samaan tarkkuuteen kuin opetuksessa. Ennusteita tehtiin viideksi ja yhdeksi päiväksi etukäteen perustuen sääennusteisiin ja lisäksi kyseisen päivän oikeilla säätiedoilla kyseiseksi päiväksi (taulukko 4). Pidemmillä ennusteilla tarkkuutta huonontaa sääennusteen luotavuuden huononeminen.

TAULUKKO 4 Ennusteen pituuden vaikutus tarkkuuteen (Choi ym., 2016)

Aikaikkuna	Tarkkuus
Viisi päivää aikaisemmin	26,8 %
Yksi päivä aikaisemmin	30,1 %
Oikealla säätilanteella	80,4 %

Kaikilla menetelmillä ennusteen tarkkuus vaatii säätiedon huomioimisen. Myöhästymisiin vaikuttavat kuitenkin monet muut tekijät, joten pelkällä säätiedolla ei voida ennustaa kaikkia myöhästymisiä. Eri menetelmien ennustamiskyky oli sikäli mielenkiintoinen, että joillekin menetelmille riitti pelkkä aikataulutieto.

Toisille menetelmille säätiedoilla oli selkeä hyöty ja toisille taas säätiedot eivät olleet hyödyllisiä (kuvio 3). Ennusteissa näyttäisi olevan tarve seurata tilannetta ja ennusteita hyvinkin lähelle varsinaista tapahtumaa. Parhaimmillaan ennusteen tarkkuus oli 83,4 %. Seuraavassa alaluvussa on vastaavanlainen tutkimus, jossa on lisäksi käytetty kehittyneempää neuroverkkoa hyväksi.

2.3.3 Lentoliikenteen myöhästymisen tilan ennustaminen sää- ja liikennetiedoilla RNN-arkkitehtuurin neuroverkolla

Tässä luvussa lähteenä on tutkimus (Kim, Choi, Briceno & Mavris, 2016), jota on hyvä verrata aiempaan tutkimukseen, jossa myös myöhästymisiä ennustettiin tapahtumina eikä ajallisesti ja lähtötiedot olivat muuten samanlaiset. Aiemmasta poiketen tiedolle ei tehty esikäsittelyä, vaan annettiin neuroverkon mukautua tilanteeseen.

Syötetiedot olivat vuosilta 2010–2015. Tutkimuksen mallissa oli kaksi vaihetta. Ensimmäinen vaihe ennusti lentokentän päivittäistä myöhästymistilaa. Toinen vaihe ennusti myöhästymistä yksittäiselle lennolle. Opetusvaiheessa ensimmäinen vaihe sai syötetiedot aikataulujen ja säätietojen historiasta. Ensimmäinen vaihe antoi lentokentälle päivittäisen myöhästymistilan, joka oli saatu keskimäärin kaikista lentokentän päivän lennoista. Toinen vaihe käytti syötetietoina lentokentän ensimmäisen vaiheen edellisen päivän myöhästymistilaa, aikataulutietoja ja säätietoja. Molemmissa vaiheissa he valitsivat opetettavaksi lentokentäksi Atlantan.

Tutkimuksessa he käyttivät neljää eri toistuvan neuroverkon arkkitehtuuria (Recurrent Neural Network, RNN). Lentoliikenteen analyysiin syväoppivia algoritmeja ei oltu aiemmin kokeiltu. Syväoppivia algoritmeja on käytetty paljon data-analytiikan ja massadatan ongelmiin, kuten liikennevirtojen ennustamiseen. Erityisesti toistuvan neuroverkon (RNN) algoritmi osoittautui tarkaksi menetelmäksi tapauksissa, joissa tarvitaan peräkkäisten ja ajallisten tapahtumien mallinnusta. Tässä tutkimuksessa käytetty RNN-ennustusmalli osoittautui tarkemmaksi kuin aiemmissa tutkimuksissa olleet mallit. Aiemmat mallit ovat usein perustuneet liikenteen mallinnuksiin ja simulointeihin (Manley & Sherry, 2010 ja Ferguson, Kara, Hoffman & Sherry, 2013 ja Glover & Ball, 2013). Simuloinneista on tutkimusten mukaan hyötyä, kun tutkitaan eri asioiden vuorovaikutuksia tai pitkälle aikavälille ulottuvia vaihtoehtoja. Simuloinnin heikkoutena on hitaus ja mahdolliset mallinnuksen epätarkkuudet. Koneoppimista on käytetty tutkimuksissa hyvin tuloksin, mutta tarkkuudessa on vielä ollut parannettavaa.

Mallin ylioppimista Kim ym. (2016) pyrkivät välttämään molemmissa vaiheissa dropout-tekniikalla. Testausvaiheessa sillä oli helppo yleistää ennustuksia ja vähentää merkittävästi ylioppimista (Srivastava, Hinton, Krizhevsky, Sutskever & Salakhutdinov, 2014). Oppimiseen Kim ym. (2016) käyttivät tilanteen mukaan stochastic gradient descent -algoritmia tai batch gradient descent -algoritmia. Lopuksi he testasivat ja yleistivät mallin. Yleistystä testattiin käyttämällä Atlantaan valittuja asetuksia ja testattiin niitä muiden lentokenttien syötetiedoilla.

Kahta erilaista peräkkäisten päivien mallia kokeiltiin. Ensimmäinen malli oli seitsemän perättäistä päivää 15 minuutin myöhästymisrajalla ja toinen oli yhdeksän perättäisen päivän malli 30 minuutin myöhästymisrajalla. Ensimmäisestä vaiheesta saatiin ennusteiden 90 % tarkkuus. Isommalla myöhästymisrajalla saatiin paremmat luokittelut.

Toisen vaiheen opetuksessa he käyttivät ensimmäisen vaiheen antamaa myöhästymistilaa sää- ja aikataulutietojen lisänä. Toisessa vaiheessa testattiin erilaisia piilokerrosten lukumääriä sekä kerroksissa olevien neuronien lukumääriä. Paras tarkkuus saatiin viidellä piilokerroksella, joissa neuronien lukumäärät olivat: 133, 300, 200, 100 ja 15. Opetukseen käytettiin 228 iteraatiokierrosta. Yksittäisen lennon myöhästymisen ennustamisen tarkkuus oli 87,4 %. Tämä oli paras tarkkuus tähän asti tehdyistä tutkimuksista. Atlantasta saatua mallia käytettiin yhdeksän muun lentokentän myöhästymisen ennustamiseen. Tarkkuus ylittää 85 % kaikilla paitsi Phoenixin kentällä. Phoenixin kentällä oli selvästi muita vähemmän liikennettä. Parhaimmillaan tarkkuus oli 91,81 % (Kim ym., 2016).

Tämän tutkimuksen tulokset olivat tarkimmat tähän asti tehdyistä tutkimuksista huolimatta siitä, että syötetietoja ei esikäsitelty vaan neuroverkko itse valitsi tietojen käytön mallissa. Uskoisin, että tuloksiin vaikutti mallin optimointi ja uuden neuroverkkotekniikan käyttö. Seuraava tutkimus pyrkii lisäksi ennustamaan myöhästymisen aikamäärää.

2.3.4 Lentoliikenteen myöhästymisen aikamäärän ennustaminen sää- ja liikennetiedoilla

Thiagarajan, Srinivasan, Sharma, Sreekanthan ja Vijayaraghavan (2017) käyttivät tutkimuksessaan kaksivaiheista ennustavaa mallia, jossa ensimmäinen vaihe ennustaa myöhästymisen tilan ja toinen vaihe myöhästymisen minuutteina. Syötetietoina olivat viiden vuoden aikataulu- ja säätiedot vuosilta 2012–2016. Syötetietojen valintaan he käyttivät Recursive Feature Elimination -algoritmia, jolla saatiin paras tarkkuus lyhyimmässä ajassa. Johtuen myöhästymisten pienestä osuudesta, tietojen tasapainoa korjattiin ennen luokittelua. Sekä isompaa (SMOTE-tekniikka) että pienempää (Tomek Links -tekniikka) ryhmää tasapainotettiin, mutta isomman ryhmän pienentämisellä saatiin parempia tuloksia.

He käyttivät luokitteluun Extra-Trees -, Random Forests -, AdaBost- ja Gradient Boosting -neuroverkkoja. Luokittelijana toimi parhaiten Gradient Boosting -menetelmä. Lähtöjen luokittelu onnistui 86,5 % tarkkuudella ja saapumisten luokittelu 94,3 % tarkkuudella.

Myöhästymisen minuuttimäärän ennustamiseen he käyttivät Extra-Trees-, Regressor-, Random Forest Regressor -, Gradient Boosting Regressor - ja Multilayer Perceptron -menetelmiä. Lisäksi syötetietojen normalisoinnin vaikutuksia kokeiltiin RobustScaler- and StandardScaler-menetelmillä. Myöhästymisen määrää ennusti parhaiten Extra-Trees Regressor -menetelmä. Lähtevien lentojen myöhästymisminuutit pystyttiin ennustamaan tarkemmin kuin saapuvien lentojen (Thiagarajan ym., 2017).

Tämä oli tutkimus, jossa menetelmän valinnalla sekä tiedon esikäsittelyllä päästiin hyviin tuloksiin. Uskoisin, että tiedon esikäsittely ja tutkimustavoitteen konkreettinen tavoite lisäsivät saatavia hyötyjä. Seuraavassa luvussa on vielä tutkimus, jossa pyrittiin tiedon esikäsittelyllä ja menetelmien valinnalla parantamaan ennustetulosta.

2.3.5 Lentoliikenteen sää- ja liikennetietojen käsittelyn optimointi

Tämän luvun tutkimuksen (Moreira, Dantas, Oliveira, Soares & Ogasawara, 2018) tavoitteena oli selvittää tiedon esikäsittelyn ja ennustemenetelmän valinnan vaikutuksia parhaan lopputuloksen saamiseksi. Syötetietoina ovat Brasilian lentoliikenne- ja sää tiedot vuosilta 2009–2015. Tiedon esikäsittelyn he tekivät tutkimuksessa normalisoimalla, järjestelemällä tärkeyden mukaan, pehmentämällä laskentaa ja lähdetietojen luokittelulla. Tiedon karsimista tehon lisäämiseksi tehtiin poistamalla toisteisuutta, samankaltaisuuksia, korrelaatioita, nolla-arvoja ja käyttämällä pääkomponentteja. Tiedon tasapainotus tehtiin SMOTE- ja RS-tekniikalla. Luokittelu malleina testattiin: k-NN-, Support Vector Machine -, Naive Bayes - ja Random Forests -luokittelumenetelmiä. Koneoppimisen metodeista paras (78,02) oli neuroverkko (NN), joka käytti back-propagation-menetelmää (Haykin, 2009). Tasapainotustekniikkaa käyttävät mallit kykenivät ennustamaan parhaimmillaan 60 % tarkkuuteen, kun ilman tasapainotusta tarkkuudet olivat 2–6 %. Parhaissa malleissa käytettiin syötetietojen valintaan ja tasapainotukseen SMOTE-metodia, jolloin päästiin 73,8 % tarkkuuteen (Moreira ym., 2018).

Myöhästymisten kaikkia syitä on vaikea saada ennustettua ja tässä tutkimuksessa käytettiin vakiintuneita syötetietoja. Erilaisia esikäsittelyn ja metodien yhdistelmiä vertailtiin ja päädyttiin tulokseen, että tiedon tasapainottaminen ja tiedon jakautuminen tasa-arvoisesti eri tietoluokissa oli tärkeää. Malleja, joissa oli epätasainen luokkien jakauma, tuli välttää. Vaikka kaikissa tutkimuksissa, joissa ei tietojen valintaa ja esikäsittelyä hyödynnetty ja saatiin silti hyviä tuloksia, kannattaa Moreira ym. (2018) mukaan tämäkin vaihe hyödyntää.

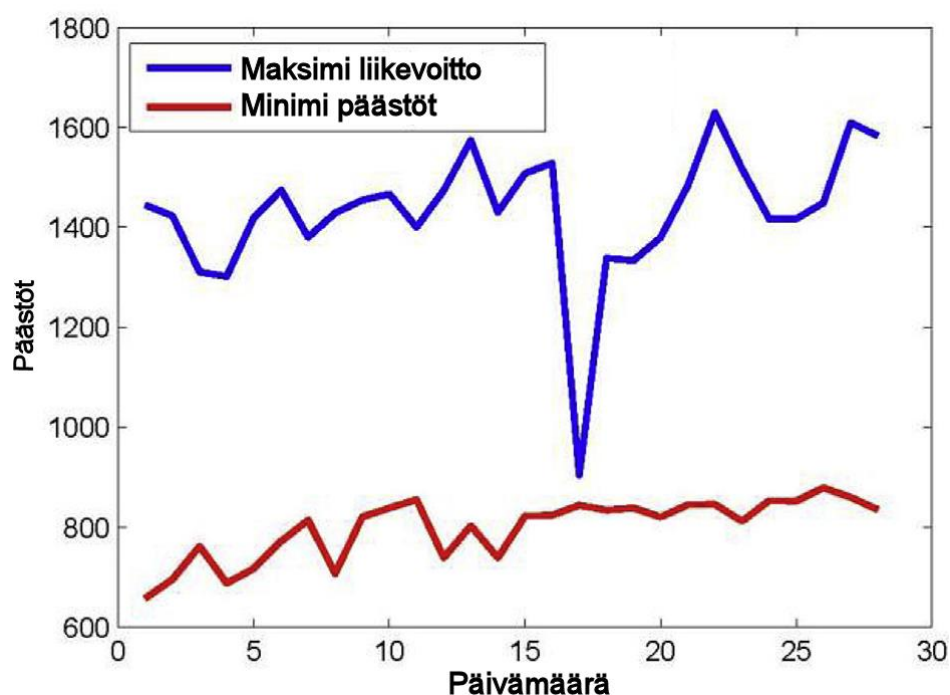
Tutkimuksia koneoppimisen käytöstä on tehty erilaisilla lähestymistavoilla koneiden myöhästymiseen liittyen. Tutkimuksissa korostuu lentokenttien erilaisuus ja tiedon esikäsittelyn sekä käytettyjen neuroverkkomenetelmien vaikutus tulokseen. Pidemmillä ja monimutkaisemmilla laskennoilla voisi esikäsittelyäkin varmaan korvata ja löytää uusia piirteitä, mutta mikään tutkimus ei maininnut esimerkiksi pilven kautta supertietokoneiden hyväksikäyttöä. Vaativammalla laskennalla saatua mallia voisi sitten käyttää hyödyksi kevyemmällä alustoilla. Massiivisia laskentoja voisi toisaalta korvata tai täydentää asiantuntijoiden ohjeiden mukaisilla esikäsittelyillä. Tällaisesta olisi esimerkkinä käytettävien kiitoteiden valintaan vaikuttavat olosuhteet, jotka koneoppiminen oppisi. Tiedon esikäsittelyllä saisi otettua mukaan asiantuntijoiden mielestä tärkeää tietoa. Merkittävä tieto olisi myös reitin sää tietojen ja -ennusteiden vaikutus lentosarjoihin. Myöskään portilta portille aikojen pitkittymistä ei huomioitu, vaikka se liittyy kiinteästi myöhästymiseen. Samalla se liittyy polttoaineen kulutukseen ja sen ennakointi on nykyisin aina vain tärkeämpi tieto talouden ja turvallisuuden

kautta. Myöhästymisen syitä ja vaikutusmahdollisuuksia pitäisi miettiä asiantuntijoiden kanssa, jotta päästäisiin hyviin tuloksiin. Esimerkiksi tieto lennon myöhästymisestä ei hyödytä lentoyhtiötä, jos myöhästymiseen ei voida vaikuttaa. Kun epäkohta on korjattu, ennustemalli ei mahdollisesti ole enää toimiva. Ennustemallin pitää oppia uudelleen. Kaikkia syitä ei voida poistaa, kuten säätilaa.

Lisänä toteuttaisin vastaavissa tutkimuksissa laajemmat lähtötiedot, ajankohtaisen tiedon lisäämisen ja asiantuntijoiden esittämiin tarpeisiin kohdistetun haun. Esimerkiksi lentoyhtiöistä olisi saatavilla myöhästymiskoodit lennoille, joista saataisiin paljon täydentävää tietoa ennusteisiin. Samoin tarkasteluun tulisi ottaa samalla koneyksilöllä tapahtuneet lennot, koska lentojen sarja suunnitellaan samalle koneelle. Sarjassa tapahtuvilla miehistön vaihdoilla on myös iso merkitys lentosarjan etenemiseen. Lentoyhtiöllä ja lentoasemalla on myös tiedot millaista pysäköintipaikkaa koneet ovat käyttäneet. Erilaisilla pysäköintipaikoilla on huomattavan erilaiset logistiikkaratkaisut matkustajien ja palvelujen suhteen. Suomessa talvi lisää lumen ja jäänpoiston vuoksi ennustettavia tekijöitä. Missään edellisissä tutkimuksissa ei näy asiantuntijoiden hyödyntäminen tai lopputulosten käytännön hyödyntäminen ja hyödyntämisen vaikutus.

Lennot ovat yleensä edestakaisia kenttäpareja. Kova vastatuuli tarkoittaa paluussa kovaa myötätuulta. Vastatuulella hävitty aika saatetaan osittain voittaa paluumatkalla, vaikka määräkentälle olisi tultu myöhässä. Myötätuulella voitettua aikaa ei voida hyödyntää, koska paluumatkalle on lähdettävä aikataulun mukaisesti - vastatuuleen. Tällainen myöhästymisen voi kertautua koko päivälle, jos lentokoneelle suunniteltua sarjaa ei voida lentää toisella koneella ja miehistöllä. Ajoissa saatava tieto tulevasta myöhästymisestä voisi mahdollistaa lentojen uudelleen järjestelyn. Etukäteen saatu tieto myöhästymisestä auttaisi myös lentojen suunnittelussa sekä optimoinnissa. Suunnittelussa voitaisiin varata sopiva määrä ylimääräistä polttoainetta ja optimoinnissa voitaisiin arvioida jäljellä oleva lentoaika, joka vaikuttaa liu'un aloitusaikaan.

Kokonaiskustannusten arvioinnissa Ferguson, Kara, Hoffman ja Sherryn artikkeli (2013) selventää eri tekijöiden vaikutusta lentoyhtiön kokonaiskustannuksiin. Kulu voi aiheutua lentoajasta, kalenteriajasta tai kuluista per lento. Lennoilla näitä erilaisia kuluja optimoidaan määrittämällä lennolle Cost Index. Cost Indexin perusteella määräytyy lentonopeudet ja polttoaineen kulutus. Lennon kustannusten optimoimiseksi lennetään kaukana polttoainekulutuksen (päästöjen) optimista. Kustannuksilla ja päästöillä on tietty suhde. Tämän suhde on kuvattu Ma, Song ja Zhun (2018) tutkimuksessa, jossa tutkittiin vähäpäästöisyyden ja kulujen kompromissia lentoyhtiölle. Alla olevassa kuvaajassa (kuvio 4) ovat erään yhtiön lentojen päästöt kuukauden eri päivinä. Mikäli kustannukset minimoidaan päästöt ovat ylempään sinisen viivan mukaiset. Jos samat lennot lennetään pienimmällä polttoaineenkulutuksella päästöt ovat alemman punaisen viivan mukaiset.



KUVIO 4 Päästöt minimi kustannuksilla ja minimi kulutuksella (Ma, Song & Zhu, 2018)

Kuvaaja osoittaa, että lentoyhtiön toimiessa pienimmillä kustannuksilla päästöt ovat kaksinkertaiset verrattuna toimintaan pienimmällä kulutuksella. Liu'un aikana tyhjäkäynnillä sekä kulutus että kustannukset ovat minimissä. Jos liuku aloitetaan liian aikaisin, tulee lisää kulutusta jouduttaessa lentämään matalalla matkalentotehoilla. Jos liuku aloitetaan liian myöhään, tulee lisää kulutusta korkealla liian pitkään käytetystä matkalentotehosta. Jäljellä olevan ajan arvioimiseen vaikuttavat esimerkiksi viikonpäivä, kellonaika, saapuva liikenne, kiitotieolosuhteet (liukkaus, lumi), lähtevä liikenne määräkentällä (ruuhkat maassa), sään ja ennusteiden vaikutus laskeutumisiin ja lentoonlähtöihin (auraus). Näiden tapahtumien arvioiminen perustuu lentäjän kokemukseen. Jos samat lentäjät ovat perättäisinä arkipäivinä samalla lennoilla, tuo arvio onnistuu paremmin. Kokemusta on vaikea jakaa, mutta koneoppimisella voidaan koota kaikkien syötetietojen vaikutus ja oppia lentäjien kokemuksia vastaava tieto. Näin saavutettu kokemustieto on helppo jakaa kaikkien lentäjien kesken.

Lippujen myynnin tavoin myös myöhästymisten ennustaminen voi hyötyä paljon lentoyhtiön omista tietovarastoista. Liu'un aloituksen optimoinnissa saadaan paljon tarkkaa tietoa lentokoneen omista lennontaltiointilaitteista. Tallentimissa olevaa tietoa voidaan hyödyntää myös lentoturvallisuuden parantamiseen, kuten seuraavassa luvussa kerrotaan.

2.4 Lentoturvallisuuden lisääminen

Lentoturvallisuus koskee kaikkea toimintaa lentoyhtiössä. Jokaisella lentoyhtiöllä on omat viranomaisen hyväksymät toimintamenetelmänsä ja laatujärjestelmänsä lentoturvallisuuden parantamiseksi. Esimerkiksi Blue1-yhtiöllä oli (Blue1, 2014) käytössään onnettomuus ja turvallisuus raportti (ASIR), tapahtumaraportti (OR), luottamuksellinen raportti, raportti viranomaiselle, tekninen raportti, matkustamohenkilökunnan raportti ja huonon sään laskeutumisen raportti. Lisäksi A340-600-lentokoneesta tallennetaan noin 600 eri parametria lennon aikana (Campbell, 2003). Näistä tiedoista kootaan seurantoja yhtiön turvallisuustilanteesta. Lentokoneen tiedot ovat rakenteisia, mutta muut yhtiön tiedot ovat pääasiassa tekstitietoa.

Tekstitiedon analyysit ovat kehittyneet vasta viime vuosina, joten suuri osa analyysistä on tehty lukemalla raportit ja tekemällä niistä koosteet. Lentokoneen tallentamia tietoja voidaan suoraan käsitellä erilaisilla ohjelmilla. Lentoturvallisuuden tutkimuksetkin painottuvat lentotietojen käsittelyyn. Lentotietoja voidaan hyödyntää turvallisuuden lisäksi menetelmien koulutuksessa sekä taloudellisten toimintatapojen kehittämisessä.

Lentotietojen analyysit perustuvat muutaman vakiintuneen ohjelmiston toimintoihin. Maillen (2013) tutkimuksen mukaan käytetyimmät ohjelmat ovat Teledyne AirFASE, Spirent ja Sagem AGS. Näiden ohjelmien toiminta perustuu tiettyjen raja-arvojen ylitysten seurantaan. NASAn Morning Report -ohjelma perustuu klusterointiin ja se etsii normaalista poikkeavia arvoja tavanomaisiin lentoihin verrattuna jatkuvasta tiedosta. Lisäksi on olemassa erillisiä työkaluja tiedon käsittelyyn, kuten MKAD. Se käyttää luokkia tukivektorikonetta (OCSVM) ja pystyy analysoimaan sekä jatkuvaa että epäjatkovaa tietoa (Das, Matthews, Srivastava & Oza, 2010). Das ym. (2013) vertailivat näitä eri tyyppisiä analysointitapoja ja totesivat täydentävistä tiedoista olevan hyötyä poikkeavuuksien syiden löytämiseksi. Miehistön toimenpiteiden selvittäminen auttoi tapahtumien syiden lisäksi lennon vaiheiden erottelussa. Heidän mukaan suurta tietomäärää voidaan hyödyntää tapahtumien ymmärtämiseksi eikä pelkästään virheiden löytämiseksi Das ym. (2013).

Toinen tutkimus, jossa Maille (2017) käytti lentotietoja hyväksi, keskittyi toimintamenetelmien seuramiseen ohjaamossa. Lentoyhtiöillä on vakiot toimintamenetelmät, jotka ovat hyväksytyjä ja parhaiksi todettuja tapoja toimia eri lennon vaiheissa. Toisen lentäjän tehdessä toimenpiteitä toinen lentäjä valvoo, että asiat tapahtuvat oikein. Vakiot menetelmät helpottavat valvontaa, kun tiedetään, mitä toisen lentäjän tulisi tehdä missäkin lennon vaiheessa. Myös tässä tutkimuksessa käytettiin MKAD-työkalua jatkuvien ja epäjatkovien tietojen seurannassa. Tutkimuksella saatiin paljon tietoa siitä, kuinka miehistö noudattaa vakioita toimintamenetelmiä. Näin voidaan vaikuttaa koulutukseen ja vakiomenetelmiin, jotta voidaan lisätä lentoturvallisuutta. Lentotietojen käyttöä voidaan näin monipuolistaa.

Smart, Brown ja Denman (2012) yhdistivät tutkimuksessaan analyysiin kaksi vaihetta. Ensin etsittiin poikkeavia lentoja ja vertailtiin niitä asiantuntijoiden valitsemiin lentoihin. Asiantuntijat määrittivät myös mitä arvoja he seuraavat lähestymisliu'un aikana. Näitä arvoja käytettiin luokittelussa. Luokittelulla pyrittiin parantamaan menetelmän osuvuutta ja samalla löydettiin uusia poikkeavia lentoja. Näiden poikkeavien lentojen lähestymisliukuja vertailtiin normaaleihin liukuihin ja pyrittiin löytämään aikainen varoitus tulevasta riskistä. Menetelminä olivat K-means-klusterointi, pääkomponenttianalyysi, OCSVM-luokittelu sekä MKAD-algoritmi. OCSVM-luokittelu osoittautui tehokkaimmaksi menetelmäksi. Saadut tiedot mahdollistivat vakiomenetelmien automaattisen seurannan (Smart ym., 2012).

Näyttäisi, että arvot olivat kiinteässä koordinaatistossa eikä tuulta, aikaa, painoa tai jäätäviä kerroksia oltu huomioitu. Lentoyhtiöllä on säännöllisin välein reittitarkastuslentoja, jolloin pyritään yhtenäistämään vakiomenetelmien noudattamista. Tämä uusi menetelmä sallisi tilanteen seuraamisen automaattisesti kaikilta reittilennoilta. Pelkkä klusterointi ilman ennakkoon luokittelua löytää poikkeavat lennot (Li, Das, Hansman, Palacios & Srivastava, 2015) ja on menetelmänä yksinkertainen.

Klusteroinnilla on monia mahdollisuuksia, mutta lentoyhtiön tarpeiden mukainen menetelmä lienee paras ratkaisu. Jos suunnitellaan ratkaisu yhtiön tarpeiden mukaan, menetelmä olisi ohjattu tai vahvistusoppimisen malli. Tällaisia malleja ei ole tutkittu. Puhtaita neuroverkkoja tai syväverkkojakaan ei ole käytetty. Kaikissa tutkimuksissa käytettiin lentokoneesta saatavia tietoja. Lentoyhtiön muiden tietojen yhdistäminen lentokoneen tietoihin lisäisi mahdollisuuksia erilaisiin ratkaisuihin. Säättiedot ja ohjaajanyksilötiedot voitaisiin yhdistää lennon tietoihin, jolloin olisi mahdollista paremmin kehittää menetelmiä ja tukea lentäjäkohtaisesti oppimista. Persoonaton opastaja olisi varmaan tervetullut lisä lentäjien koulutukseen. Yksilöistä puhuttaessa lentäjän ajatukset menevät helposti lupakirja ja palkka-asioihin. Vertailut kollegoihin voi olla arka asia. Tekoäly avulla voitaisiin säilyttää yksityisyys. Toinen riski voisi olla toiminnan liika tehostaminen, jolloin liika säästäminen maksaisi lentoturvallisuuden huonontumisena. Seuraavissa luvuissa toiminnan seuraaminen ja automatisointi ollaan viety lähemmäs lentäjiä.

3 Hyödyntämättömiä koneoppimisen kykyjä

Tässä luvussa käsittelen tutkimuksia, joiden tuloksia ei ole hyödynnetty. Ensimmäisenä mukautuva automaatio, joka toimii tarkastavana ohjaajana ja tarvittaessa autopilotin käyttäjänä ja toisena tekoälyn ohjaama autopilotti. Mukautuvaa automaatiota voidaan käyttää lennon tallentimien tapaan tapahtumien seuraamiseen, mutta automaatiolle voidaan antaa valvonta, avustus ja ohjaamistehtäviä. Automaatio voi jopa aloittaa ohjaamisen ilman ihmisen antamaa käskyä.

Autopilotin tehtävänä on lentokoneen ohjaaminen halutulla tavalla. Tällainen pelkkään ohjaamiseen keskittyvä automaatio on toteutettu sääntöpohjaisilla ohjelmilla. Toisessa alaluvussa kerron mahdollisuudesta opettaa tekoäly lentämään lentokonetta.

3.1 Mukautuva automaatio

Automaation muuttuessa älykkäämmäksi sille voidaan lisätä muitakin kykyjä kuin lentokoneen ohjaaminen. Autopilotti on usein rinnastettu kolmanteen lentäjään ohjaamossa. Lentäjät käskyttävät ja hallitsevat tätä kolmatta lentäjää. Automaation ongelmina ovat automaation yllätykset, huonontunut tilannetietoisuus, tahaton huomaamattomuus, työtaakkaa koskevat ongelmat ja ongelmat, jotka liittyvät liialliseen automaatioon.

Euroopan komission rahoittamassa tutkimuksessa on toteutettu vuosina 2013–2016 seitsemän maan yhteistyönä A-PiMod-projekti (Deutsches zentrum fuer luft - und raumfahrt ev., 2016). A-PiMod-projektin tutkimuksessa kehitettiin uusi arkkitehtuuri mukautuvaan ohjaamoon, joka vähentää inhimillisiä virheitä ja pyrkii Euroopan strategiseen tavoitteeseen vähentää onnettomuuksien määrää 80% (Directorate General for Mobility and Transport, 2011). Yhteisöön kuului osallistujia ilmailun 19 toimialasta. Onnettomuusanalyysissä kaikki 19 osallistujaa ilmoittivat, että A-PiModilla oli merkittävä rooli lento-onnettomuuksien estämisessä. Lentäjät arvioivat arkkitehtuurin ja työkalut hyödyllisiksi ja olivat sitä mieltä, että ne auttavat vähentämään virheitä ohjaamossa. Kaikkiaan toteutettiin 27 arviointitilaisuutta tutkimus- ja innovaatioyhteisön kanssa (Cahill, J., Callari, Fortmann, Javaux & Hasselberg, 2016). Turvallisuusvaikutusten arviointi osoittaa, että A-PiMod-lähestymistapaa käyttämällä onnettomuuksien määrä vähenisi 43% (Stroeve, Van Doorn & Cahill, 2016).

A-PiMod-arkkitehtuuria kehitettiin tutkimuksessa, joka pyrki saamaan ihmisen ja automatiikan toimimaan yhdessä tilanteeseen mukautuvalla tavalla (Kaber & Riley, 1999). Automatiikan tuli mukautua sekä ihmisiin että tilanteeseen, jotta toiminta olisi joustavaa sekä turvallista. A-PiModissa on kolme toisiaan täydentää osiota: mukautuva lentotehtävän seuranta ja suoritus, mukautuva automaatio ja mukautuva miehistön ja automaation vuorovaikutus.

A-PiMod huomioi ihmisen käyttäytymisen kognitiivisten mallien avulla ja luo reaaliaikaisen arvion lentäjän mentaalista tilasta. Tämän arvion perusteella automaatio antaa suosituksia, mukautuu tai puuttuu toimintaan. Arkkitehtuuri perustuu kolmeen osioon: tehtävä, ohjaamo ja lentäjä keskeiseen osioon. Osioiden välisessä vuorovaikutuksessa huomioidaan osioiden tilanne, vaihe, riippuvuudet, muutokset ja riskit. Tehtävien jakaminen ja automaation taso sekä ehdotukset perustuvat tähän kokonaisuuteen (Cahill ym., 2017.).

Lentäjän kognitiivista tilaa arvioidaan automaattisesti neljällä arviolla:

- Aikomukset : mitä tehtäviä lentäjä aikoo tehdä?
- Käyttäytymisen seuranta : katsooko lentäjä asiaankuuluvia näyttöjä?
- Tilannetietoisuus : tekeekö lentäjä tehtävät, joista hän vastaa?
- Kuormitus : onko lentäjällä liikaa tehtäviä vastuullaan?

Näihin arvioihin käytetään tekniikkaa, joka ei ollut mahdollista ennen koneoppimisen nykyistä kehitystä. Puheen tunnistus vaatii neuroverkkojen, ivektoreiden sekä syvien neuroverkkojen käyttöä. Syväoppimisesta (DNN) oli paljon apua ivекtori perusteisissa metodeissa, kun tunnistettiin puhetta (Cao & Benes, 2014.). Kuvan ja eleiden tunnistus mahdollistaa sekä eleillä käskytyksen että liikkeiden tunnistuksen. Asennon tunnistuksessa käytettiin Random Forest -metodia sekä syväoppimista. Syväoppimisen kyvyt todettiin hyviksi asennontunnistuksessa. Eleiden tunnistuksen algoritmit tunnisti toimenpiteitä ohjaamossa. Passiivinen katseen seuranta toteutettiin tuetuilla vektorikoneilla ja neuroverkoilla. Neuroverkkojen toiminta oli nopeaa ja tarkkaa. Huonoina puolina he mainitsivat herkkyuden ja pään paikannuksen epätarkkuuden. Passiiviseen seurantaan todettiin tarvittavan useiden eri menetelmien yhdistelmää. Ohjaamoon (simulaattorin) sijoitettu kamera tallensi tiedot, jotka käsiteltiin koneoppimisella. Silmän seurannan tuloksena tiedetään lentäjän katseen suunta, jota käytettiin seuraamaan vaadittujen tehtävien suorittamista. Näin voitiin arvioida lentäjien tehtävien valvontaa ja valvonnan riittävyyttä (Cao, Pavelkova & Behun, 2013.).

Ohjaamossa lentäjien ja automaation tehtävien jakautuminen tulisi olla oikea suhteessa tilanteeseen. Käyttölaite vastaa ohjaamotason tehtävien sopivasta jakautumisesta miehistön ja automaation välillä ja ehdottaa tehtävien jakamista miehistön ja automaation kesken. A-PiMod parantaa ihmisen ja koneen välistä yhteistyötä reaaliaikaisesti. Miehistön sisäisiä tiloja tulkitaan, jotta automaation osuus voidaan mukauttaa tarpeiden mukaan. A-PiMod seuraa tilannetta ja tarvittavia tehtäviä ja niihin liittyviä riskejä sekä varoittaa miehistöä, mikäli tehtävien suorituksessa on puutteita. Lentäjät voivat käyttää puhe-, kosketus-, kursori- tai näppäimistöohjausta.

A-PiModin koulutussovellus vaikuttaa turvallisuuteen myös parantamalla lentokonemiehistön koulutusta simulaattorissa. Se voi seurata tapahtumia ja seurauksia, jolloin seurantatietoja voidaan hyödyntää tutkimuksessa ja menetelmien kehittämisessä. Miehistön tilan seuranta ja tapahtumien huomioidaan tehdään automaattisesti. Miehistön arviointia voidaan parantaa tavoitteen

hallinnan, miehistön tilan ja lentoarvojen automaattisella seurannalla. Opetuspalaute saadaan koulutuksen jälkeen koulutustyökalun arvioiden perusteella monipuolisemmaksi. A-PiMod-malleihin perustuva koulutus on erityisen hyödyllinen miehistöyhteistyön kouluttamisessa ja ylläpitämisessä. Lisäksi se mahdollistaa tehokkaamman koulutuksen tukemalla opettajaa ohjaamoyhteistyön arvioinnissa seuraamalla ohjaamomiehistön henkistä tilaa ja stressitasoa. Koulutuksen kustannustehokkuutta parannetaan avustamalla lentosimulaattorikouluttajia uudella koulutusvälineellä ja koulutusmenetelmillä, jotka perustuvat A-PiMod-malleihin ja käyttäytymistietojen keräämiseen.

A-PiModin käyttö muuttaisi selkeästi ohjaamoyhteistyön menetelmiä. Mikäli lentoyhtiöllä olisi erilaisia versioita konetyypistä mukautuvan automaation suhteen, vaadittaisiin kahdet menetelmät konetyypille. Toisaalta vikatilanteen varalta pitäisi joka tapauksessa varautua mukautumattomaan automaatioon. Järjestelmä tasoittaisi eri tasoisten lentäjien ongelmaa nostamalla ohjaamoyhteistyön tasoa heikommilla miehistöillä. Jo pelkästään koulutuksessa käytettynä se antaisi lisää hyötyjä lentoyhtiölle.

Edellisessä kappaleessa tutkittiin lennontallentimien hyödyntämistä. Älykkäämpi automaatio estäisi joutumisen tilateisiin, joissa tallentimia tarvitaan. Onnettomuustilanteissa olisi monipuolinen tilanteenarvio käytettävissä, jos tilanne pääsisi etenemään niin pitkälle. Pelkän järjestelmätiedon lisäksi saataisiin näkö ja kuulohavaintoihin ja niiden tulintoihin perustuvaa tietoa lennon kulusta. Inhimillisten rajoitteiden ja olettamien osuutta saataisiin vähennettyä automaattisella seurannalla. Järjestelmän toimivuutta olisi varmaan arvioitava perusteellisesti simulaattorissa, mutta jo siinä vaiheessa saatavat hyödyt olisivat merkittävät työskentelymenetelmien kehittämisen osalta.

Lukijalle saattaa tulla ajatus toisen lentäjän korvaamisesta älykkäämmällä automaatiolla. Tutkimuksessa ei otettu kantaa mukautuvan automaation mahdollisuuksista korvata lentäjä, mutta automaatiolta vaadittaisiin huomattavia taitoja, mikäli lentäjä saisi sairaskohtauksen eikä kykenisi tehtäviinsä. Seuraavassa luvussa kerrotaan tutkimuksista, joissa tekoälylle opetettiin lentämistä ihmistä matkimalla.

3.2 Automaattinen tekoälyohjaus

Tässä luvussa esittelen lentokoneen autopilotin ohjauksen toteuttamista oppivalla tekoälyllä. Ensimmäiset versiot autopiloteista osasivat lentää lentäjän määrittämää suuntaa ja korkeutta. Nykyiset autopilotit saavat tietonsa lentäjän lisäksi lennonhallintajärjestelmältä. Autopilotin toiminnalla on kuitenkin omat rajoituksensa, joita voitaisiin korvata automaattisella tekoälyohjauksella

3.2.1 Nykyisten autopilottien turvallisuusongelmat

Nykyiset kehittyneet autopilotit (AFCS) kykenevät ohjaamaan lentokonetta vain tietyissä rajoissa, jotka niihin on ohjelmoitu. Lentäjän pitäisi AFCS:n irti kytkeytyessä olla tilannetietoinen ja jatkaa ohjaamista tietäen, miksi autopilotti kytkeytyi irti ja mikä oli lennon vaihe kyseisellä hetkellä. AFCS:t käyttävät hyväkseen erilaisia ohjausteorioita. Näiden teorioiden mukaisesti toimivat mallit tulee suunnitella toimivaksi erilaisissa lentotilanteissa sekä hätätapauksissa. Mikäli teoriaa ei ole suunniteltu kyseiseen tilanteeseen, autopilotti kytkeytyy pois ohjauksesta. (Nelson, 1998.) Siirtymävaiheet automaattisesta ohjauksesta käsin ohjaamiseen ovat aina hetkiä, joihin liittyy lentoturvallisuusriski. Tästä on hyvänä esimerkkinä Air France lento AF447, joka joutui vakavan turbulentsisuuden alueelle ja nopeuden mittausjärjestelmä jäättyi. Tilanteessa autopilotti kytkeytyy irti nousussa ja lentokone sakkasi. Lentäjät eivät ehtineet tajuta mitä tapahtui ja kone syöksyi mereen. (Conversy, Chatty, Gaspard-Boulin & Vinot, 2014.)

Autopilotti saattaa kytkeytyä irti, kun lennolla tapahtuu esimerkiksi moottorihäiriö. Tällöin lentäjillä on moninaisia tehtäviä samanaikaisesti ja automaattisesta ohjauksesta olisi suuri etu, jotta ohjaajat voivat keskittyä itse tapahtumaan ja ongelman selvittämiseen. (Salmon, Walker & Stanton, 2016.) Sherry L. ja Mauro R. (2014) ovat kirjassaan todenneet, että vaativissa olosuhteissa AFCS:n käyttäytyminen voi olla syynä useisiin lento-onnettomuuksiin.

Khan, Tiasha ja Barmanin (2017) mukaan ilmailuteollisuus etsii nykyisin ratkaisua, jolla lentomiehistä ottaisiin vähemmän riippuvaisia. Kehittämällä autopilotti, joka toimii vaativissakin tilanteissa, voidaan vähentää työkuormaa, inhimillisiä erehdyksiä ja stressiä lennolla. Autopilottin toimintoihin ei tarvitse puuttua niin usein. Etäohjatuissa järjestelmissä ei ole samaa tuntemusta lennon tapahtumista kuin koneessa olevilla lentäjillä. Kiihtyvyyksien tunteminen, äänet ja värinät puuttuvat, joten on haastavaa kehittää täysin itsenäinen järjestelmä, joka korvaisi koneessa olevat lentäjät (Khan, Tiasha, & Barman, 2017).

3.2.2 Koneoppimiseen perustuva ohjausjärjestelmä

Seuraavissa alaluvuissa esittelen tutkimuksia, joissa opetetaan lentämistä tekoälylle ilman sääntöpohjaisia ohjelmia. Oppiminen tapahtuu lentäjiä matkimalla. Baomar ja Bentley (2016a, 2016b, 2017a & 2017b) kehittivät tutkimuksissaan koneoppimiseen perustuvaa älykstä automaattiohjausta (IAS).

Älykstä autopilottia opettaessa syötetään tietoja koneen tilasta ja asenosta kullakin hetkellä sekä tietoja, kuinka ihminen reagoi kyseisessä lentotilassa tapahtumiin. Näin saadaan enemmän tapahtumia ja tilanteita, joihin lentokoneen automaattiohjaus voi reagoida nopeasti irti kytkeytymättä. Neuroverkon opettaminen on erillinen hidas tapahtuma, mutta opittu malli on nopea ja monia samanaikaisia asioita huomioiva malli (Young-Keun & Cyungho, 1995). Älykäs autopilotti reagoi kahdenlaisiin ohjausvaatimuksiin. Alemman tason vaatimuksena ovat nopeat korjausliikkeet lentotilassa esimerkiksi turbulentsisuudesta johtuen (Ng & Russell, 2000). Ylemmän tason vaatimuksena ovat strategiset tavoitteet,

kuten navigointi, laskun tekeminen ja hätätilanteisiin reagoiminen (Sammut & Morales, 2004). Koneoppimisen on pyritty käyttämään vain vähän oppimiskerrosia sisältäviä neuroverkkoja, koska näin voidaan paremmin seurata neuroverkon sisällä tapahtuvia toimintoja. Jos neuroverkoissa käytettäisiin useita toimintoja ja oppimistasoja, rakentuisi monimutkainen syvä neuroverkko, josta olisi hyvin vaikea selvittää mitä järjestelmässä tapahtuu. Kehittyneimmillä tutkimuslennoilla koneoppiva järjestelmä pystyi lentämään itsenäisesti aloittaen rullaamista ja tehden itsenäisesti lentoonlähdöt, navigoinnin ja laskeutumisen sekä reagoitit ilmassa tapahtuneisiin moottorihäiriöihin.

Opetusvaiheessa koneoppivalle järjestelmälle kerättiin tietoja lennoilta niin, että konetta lennettiin sekä helpoissa että vaativissa olosuhteissa lentäjän ohjaamana. Lennoilta kerättiin tiedot lentotilasta ja tapahtumista sekä lentäjän reagoinnista niihin. Opetusvaiheen tiedot vietiin neuroverkolle, joka laskee painotukset eri tapahtumille ja ohjauskäskyille erilaisiin lentotilanteisiin. Tätä mallia käytettiin ohjausjärjestelmässä testilennoilla. Testilennoilla tutkittiin, kuinka hyvin koneoppiva ohjausjärjestelmä kykenee ohjaamaan lentokonetta erilaisissa vaativissa olosuhteissa.

Opetus- sekä testilennot lennettiin simulaattorilla, joka oli suunniteltu tiedon tallennusta ja koneoppivaa ohjausjärjestelmää varten. Oikealla lentokoneella ei tehty lentokokeita, mutta tarkoituksena on käyttää hyväksi tutkimustuloksia miehittämättömillä ilma-aluksilla. Käytetty simulaattori on useissa tutkimuksissa (Wei, Amaya-Bower, Gates, Vasko & Rose, 2016 ja Jirgl, Boril & Jalovecky, 2015 ja Kaviyarasu & Kumar, 2015) käytetty lentosimulaattori X-plane. Sillä voidaan mallintaa useita konetyyppejä suurista Boeing 777 -koneesta pienempiin 1-moottorisiin Scene Viber -koneisiin. Useat yhtiöt ovat käyttäneet X-plane simulaattoria, kuten NASA, Boeing, Cirrus, Cessna, Piper, Precession Flight Controls Incorporated, Japan Airlines ja Amerikan ilmailuviranomainen.

3.2.3 Nousu matkalentokorkeuteen

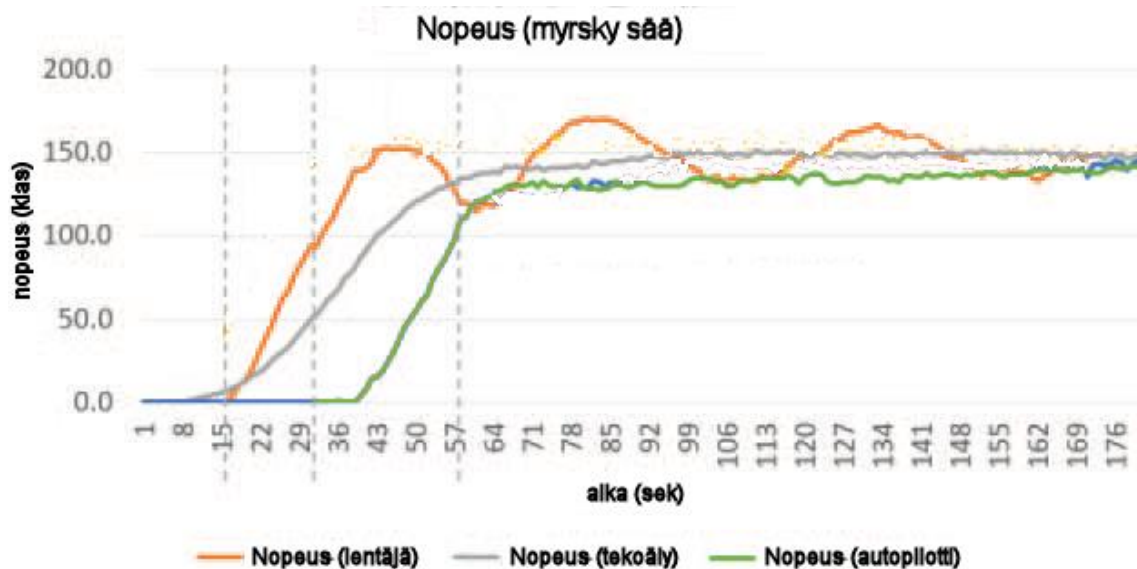
Ensimmäisessä tutkimuksessa (Baomar & Bentley, 2016a) koneoppiva ohjausjärjestelmä suoritti itsenäisen lentoonlähdön ja nousi matkakorkeuteen. Tekoälyjärjestelmä otti myös lentoonlähdössä telineen ja siivekkeet sisään sekä käytti moottoritehoja ja jalkajarruja, kuten oikea lentäjä. Myrskysäätä simulointiin 33 solmun tuulella mistä tahansa suunnasta puuskien ollessa maksimissaan 19 %. Sää oli sateinen tai raesateinen. Tekoälyn oli siis osattava tehdä lentoonlähtö voimakkaassa sivutuulella.

Opetusvaiheen rullauksen ja lentoonlähdön aikana oikean lentäjän oli korjattava jatkuvasti peräsimellä suuntaa pysyäkseen rullaus- ja kiitotiellä. Tuulen vaihdellessa ja kääntäessä konetta oikealle ja vasemmalle peräsimen tehoa autettiin myös siivekkeiden käytöllä. Tekoälyn lisäksi testit tehtiin pelkällä autopilotilla, joka usein kytkeytyi pois vastaavissa sääolosuhteissa. Myrsky sää vaikutuksesta lentokone jopa sakkasi autopilotin ohjauksessa.

Tutkimuksessa käytettiin neljää neuroverkkoa:

- Ensimmäinen neuroverkko sai tiedot nopeudesta ja korkeudesta. Se sääti moottoritehoja, telineitä ja jalkajarruja.
- Toinen neuroverkko sai tiedot nopeudesta, korkeudesta ja nokan pystyasennosta. Se sääti korkeusperäsimen asentoa.
- Kolmas neuroverkko sai tiedon kallistuskulmasta. Se sääti ohjaussiivekkeiden asentoa.
- Neljäs neuroverkko sai tiedon ohjaussuunnasta. Se sääti suunta-peräsimen asentoa.

Testilennoilla tehtiin kahdenlaisia kokeita. Ensimmäinen oli tyynessä säässä ja toinen testi oli myrskyisessä säässä. Tarkoituksena ensimmäisessä tutkimuksessa oli säilyttää lentonopeus nousun aikana. Testissä simuloitiin Cirrus Vision SF50 lentokonetta, joka on yksimoottorinen kevyt suihkukone. Testissä vertaillaan ihmisen, tekoälyn ja autopilotin kykyä nopeuden säilytyksessä lento-önlähdön jälkeen vakiintuneessa nousussa. Alla oleva kuvio 5 on testistä tyynessä sekä myrskyisessä säässä.



KUVIO 5 Nopeuden säilytys alkunousussa (Baomar & Bentley, 2016a)

Tekoäly pystyi matkimaan ihmisen toimenpiteitä ja käytöstä huomattavan tarkasti. Ohjainpintojen liikettä seurattaessa tekoäly osasi hyvin vastata myrskyssä muuttuneisiin olosuhteisiin jopa tyynessä säässä opetetulla tiedolla. IAS pystyi ohjaamaan lentokonetta vaikeissakin olosuhteissa, kun taas autopilotti kytkeytyi pois päältä usean kerran vastaavissa olosuhteissa. Tilanteissa, joihin sitä ei ollut opetettu (sakkauksessa ja inversio) tekoäly ohjasi lentokonetta turvallisesti ja itsenäisesti. Koko opetustapahtuma lentoineen ja koneoppimiseen kesti kuhunkin osatehtävään alle 20 minuuttia. Kokeet osoittivat ohjatun oppimisen kyvyt hallita sekä matalan että korkean tason tehtäviä pyrittäessä tarkkaan nopeuden säilyttämiseen.

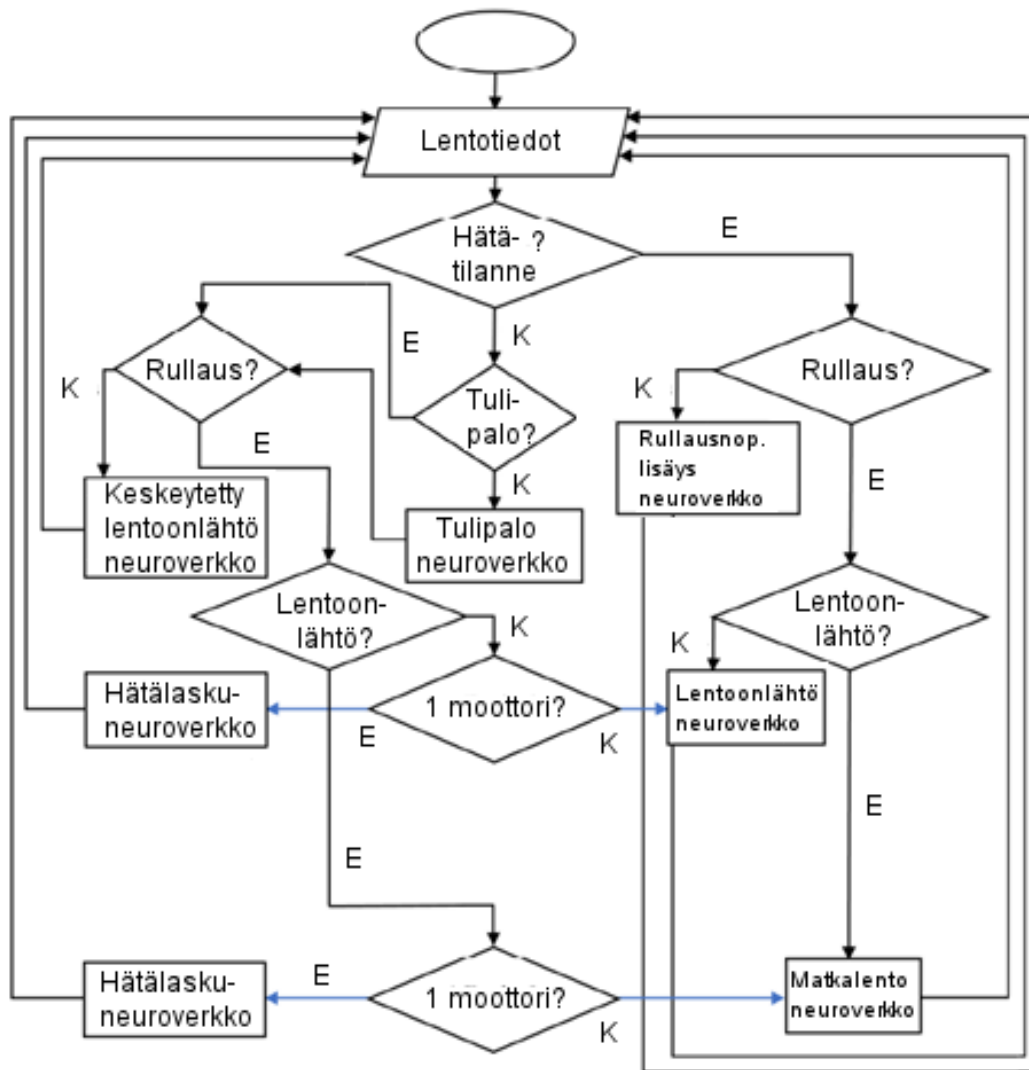
Tutkimus osoitti, että tekoälyllä on hyvät mahdollisuudet tehdä automaattinen ohjaus uudella tavalla. Lentotehtävä oli vaatimaton eikä vaatinut monimutkaisia ratkaisuja. Menetelmänä tekoälyn opettaminen osoittaa sen kyvyn oppia lentotehtävä ilman monimutkaisia sääntöjä pelkän esimerkin avulla. Seuraavassa luvussa tutkitaan neuroverkkojen lukumäärän lisäämistä, jotta saadaan useampia toimintoja tekoälylle. Niissä testataan tekoälyn kykyä oppia itsenäinen toiminta moottorihäiriössä sekä lento-onlähdön keskeyttämisessä.

3.2.4 Häätätapauksen toimenpiteet

Tämän luvun tutkimuksen (Baomar & Bentley, 2016b) tavoitteena oli opettaa tekoälylle hätätoimenpiteiden tekeminen. Hätätöimenpiteet tehdään lentokoneen vikaantuessa. Tekoälylle opetettiin moottorihäiriö, moottoripalo, keskeytetty lento-onlähtö ja hätälaskeutuminen. Näissä tehtävistä tekoäly suoriutui hyvin. Autopilottin kyky toimia tällaisessa tilanteessa on hyvin rajattu.

Nykyiset klassiset ja modernit autopilotit käyttävät erilaisia ohjausmenetelmiä, kuten Proportional Integral Derivative (PID) ohjaus ja Finite-State-automaation (Nelson, 1998). Nykyisin on pyritty kehittämään autopilottijärjestelmiä, jotka sietävät vikoja ja häiriöitä. Jotta vikoja ja häiriötä voitaisiin käsitellä, tarvitaan vika- ja häiriötilanteet tunnistava järjestelmä. Lisäksi autopilotin tulisi kyetä toimimaan oikein eri vikatilanteissa. Useista sensorista saatavan tiedon käsittelyä monimutkaisessa tilanteessa on vaikeaa ohjelmoida. Tilanteen jakaminen osiin ja usean neuroverkon käyttäminen tilanteen hallinnassa näyttäisi olevan hyvä ratkaisu (Oliveira & Neto, 2013). Laaja neuroverkko on jaettu useisiin osiin, jotka toimivat itsenäisesti. Tällainen lähestymistapa lyhentää neuroverkon opetusai-koja ja helpottaa tilanteen hahmottamista (Phan, Maul & Vu, 2015).

Tämän tutkimuksen tekoälyn muodostivat 10 neuroverkkoa. Lisänä edelliseen tutkimukseen tarvittiin lennonhallintaohjelma, joka päättää, mitä neuroverkkoa käytetään missäkin lennon vaiheessa tai hätätöimenpiteissä. Lennonhallintaohjelman kaavio on kuviossa 6.



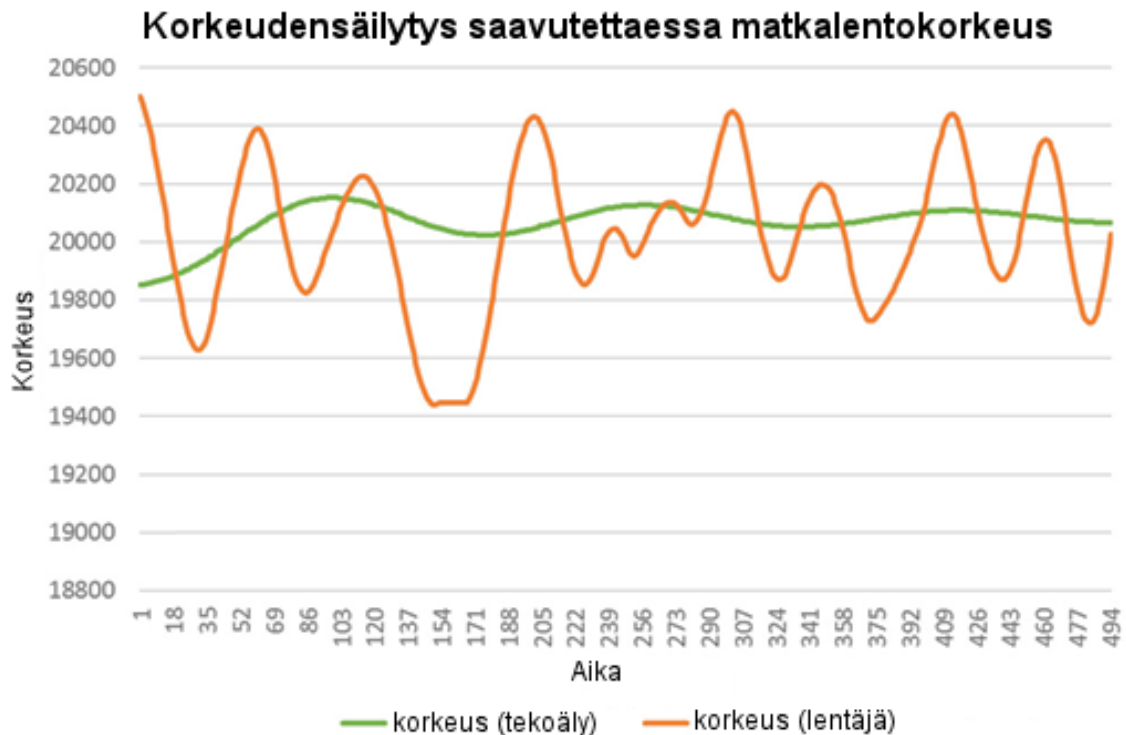
KUVIO 6 Lennonhallintaohjelmiston kaaviokuva (Baomar & Bentley, 2016b)

Toinen tutkimus jakautui neljään testiin: keskeytetty lento-önlähtö, hätälasku-önmä, matkalentokorkeuden säilytys moottorin sammussa tai moottoritulipalossa. Lentokoneen simulaattorissa käytettiin Boeing 777 -lentokoneen mallia, joka on iso monimoottorinen suihkukone.

Tutkimuksessa simulointiin keskeytettyä lento-önlähtöä siten, että yksi tai molemmat moottorit sammuiivat tai syttyivät tuleen, jolloin lento-önlähtö keskeytettiin välittömästi. Keskeytyksessä käytettiin maksimi jarrutusta. Jos samanaikaisesti oli tulipalo, suljettiin polttoainehanat ja laukaistiin palonsammutusjärjestelmä. Lisäksi käytettiin täyttä tehovivun asentoa, jotta polttoaine saatiin pois palavasta moottorista. Keskeytetyn lento-önlähdön testeissä teko-öly toimi aina oikeilla menetelmillä.


Hätälasku-önmä suoritettiin hallitulla liu'ulla laskeutumisalueelle sakkauttamatta lentokonetta ja säilyttäen pieni positiivinen nokan asento. Moottoritehoa käytettiin hyväksi, jos sitä oli jäljellä. Jos havaittiin tulipalo, polttoainehanat suljettiin ja moottorit sammutettiin. Samalla avattiin tehovipu palavassa

moottorissa polttoaineen poistamiseksi. Testissä tekoäly toimii oikeilla menetelmillä jokaisella testilennolla. Matkalentokorkeuden säilyttämistä hätätilanteessa testattiin matkimalla lentäjän käytöstä. Testissä seurattiin nopeutta ja korkeutta, joita säädettiin nokan asennolla sekä tehovivulla säilytyksessä (kuvio 7).



KUVIO 7 Korkeuden säilytys hätätilanteessa (Baomar & Bentley, 2016b)

Tehon käyttö ja matkalentokorkeuden säilytys olivat tavoitteen mukaisia. Ne osoittavat, kuinka tekoäly suoriutuu lentäjiä paremmin tästä osatehtävästä. Sama näkyi myös hätälaskeutumisen testissä. Moottorihäiriön ja tulipalon testaus lennolla tehtiin siten, että autopilotille ei opetettu uutta käyttäytymismallia, vaan testattiin jo opettuja neuroverkkoja moottorihäiriötilanteessa. Moottorihäiriössä sammunut moottori synnyttää vastusta, jolloin lentokone pyrkii vajoamaan ja kääntymään sammuneen moottorin suuntaan. Kaikilla testilennoilla tekoäly seurasi tarkasti oikeita toimenpiteitä moottorihäiriön sekä tulipalon suhteen. Koska autopilotti ei tiedä mitään moottorihäiriötilanteesta, se lisää tehoja aggressiivisesti, mistä johtuu pienempi korkeudenmenetyks. Kuitenkin aggressiivinen tehon käyttö aiheuttaa suuren rasituksen käyvään moottoriin, mistä saattaa olla katastrofaaliset seuraukset jäljellä olevaan moottoriin (kuvio 8).



KUVIO 8 Tehovipujen käyttö hätätilanteessa (Baomar & Bentley, 2016b)

Järjestelmä kykeni matkimaan useita lentäjän taitoja ja käyttäytymisiä muutaman rajoitetun esimerkin avulla. Tekoäly suoriutui hyvin matalan tason lentotehtävistä sekä korkean tason tehtävistä, kuten tehtävien koordinoiminen keskeytystä lentoonlähdössä ja tulipaloissa. Osakokonaisuuksiin jakaminen ja neuroverkkojen lisääminen paransivat suorituskykyä ja tarkkuutta lentotehtävissä.

Tutkimuksessa saatiin tekoäly toimimaan inhimillisesti tehovipujen käsittelyssä ja siitä seuraavassa korkeuden säilytyksessä. Vastaavaa kykyä on vaikea saada sääntöpohjaisesti ohjelmoitua autopilottiin. Tärkeä ominaisuus tässä tutkimuksessa oli, että häiriötilanteessa tekoäly jatkoi toimenpiteitä sekä ohjaamista eikä siirtänyt vastuuta lentäjälle. Lentäjänä on helpompi keskittyä muihin tilanteen vaatimiin tehtäviin, kun ohjaaminen ja toimenpiteet onnistuvat pelkällä tilanteen seurannalla.

3.2.5 Lentoonlähdestä laskeutumiseen

Tämän luvun tutkimuksen (Baomar & Bentley, 2017a) tavoitteena oli opettaa tekoälylle itsenäinen lentäminen lentoonlähdestä laskuun asti automaattisesti. Nykyiset autopilotit ohjaavat erilaisissa lennon vaiheissa lentäjän tekemien valintojen perusteella. Edellisten tutkimusten lisäksi tekoälylle opetetaan navigointi, liu'un aloitus, lähestyminen ja laskeutuminen. Konetyyppinä käytettiin simulaattorissa Boeing 777 -lentokonetta.

Neuroverkolle opetettiin siivekeohjaus liittymällä kaarrolla halutulle lentolinjalle. Tätä neuroverkkoa opetettiin myös lähestymisen ja laskun aikaiseen

ohjaamiseen. Lähestymisvaiheessa opetettiin vakaan liu'un säilytys ja telineiden sekä laskusiivekkeiden valinta tietyllä korkeudella ja nopeudella. Laskeutumisvaiheessa tekoälylle opetettiin lentäjän tekemät toimenpiteet: reverssin, jarrutuksen ja spoilerien käyttö.

Lähestymisessä ja laskeutumisessa suoritukset olivat yhtäläiset lentäjän ja tekoälyn tekeminä. Tekoälyn käyttö vähentäisi työtaakkaa, inhimillisiä virheitä ja stressiä normaaleissa tilanteissa. Tästä olisi apua erityisesti, jos toinen lentäjä menettää toimintakykynsä.

3.2.6 Poikkeavat tilanteet

Tämän luvun tutkimuksen (Baomar & Bentley, 2017b) tavoitteena oli opettaa tekoälylle loppulähestymislinjaan liittymistä ja ylösvedon lentämistä vaikeissa sääolosuhteissa (voimakkaalla sivutuulella, puuskissa, turbulenssissa ja windshearrissa).

Laskussa sivutuulen kumoamiseksi on kaksi menetelmää (Flight Safety Foundation, 2000). Ensimmäisessä lennetään nokka kohti tuulta ja toisessa menetelmässä lennetään kone kallistettuna tuuleen päin pienessä sivuluisussa. Tekoälyä opetettiin sivutuulen huomioimista lentäjän tehdessä sivutuulilaskuja. Nykyaikaiset autopilotit kykenevät toimimaan vain omissa toimintarajoissaan, joiden ylityksen jälkeen ne luovuttavat ohjaamisen lentäjälle. Lähestymisen aikana tekoäly oppi lentämään tuulikorjatulla nokan asennolla, jossa nokan suunta poikkeaa lentosuunnasta osoittaen tuuleen päin. Tuulikorjaus pitää laskea perinteisesti autopilotille, mutta tekoäly oppi arvioimaan sen itse. Puuskista huolimatta kone pysyi vaaditussa asemassa kiitotiehen nähden jopa kohtisuoralla 50 solmun sivutuulella, joka ylittää Boeing 777 koneen rajat laskussa.

Juuri ennen laskeutumista tarkistetaan, onko turvallinen laskeutuminen mahdollista. Lennonhallintajärjestelmä tekee turvallisella korkeudella tarkastuksen. Lennonhallintajärjestelmä tarkastaa lentokoneen suunnan kiitotien keskilinjaan nähden suhteessa kiitotien leveyteen. Sitten tarkistetaan, onko kiitotie koneen alla ja lopulta, että mikä on jäljellä olevan kiitotien määrän. Jos lennon valvontajärjestelmä toteaa, että lasku ei ole turvallinen, se tekee ylösvedon voimassa olevan menetelmän mukaisesti ja aktivoi ylösvedon neuroverkon. Ylösvedo tehdään keskeytetyn laskeutumisen jälkeen lisäämällä täysi teho, nostamalla nokka nousuun ja ottamalla telineet ja siivekkeet sisään. Ylösvedon jälkeen lentokone hakeutui takaisin laskeutumis suunnan kiitotien jatkeelle ja lensi uuden lähestymisen ja laskun.

Nämä neljä tutkimusta osoittivat tekoälyn hyödyt perinteiseen autopilottiin verrattuna. Toimenpiteet ja ohjaaminen perustuvat ihmisen tapaan toimia, mitä on vaikea toteuttaa sääntöpohjaisella ohjelmoinnilla. Pienelläkin opetuksella päästään hyviin tuloksiin. Automaattinen ohjaus suoriutuu ilman toimintarajoja eli pysyy kytkettynä vaativissakin tilanteissa. Toiminnan muuttuessa enemmän automatisoiduksi tulisi varmaan tarvetta uusille menetelmille, jotta tekoälyn itsenäistä toimintaa voidaan valvoa ja muuttaa. Toimintalogiikka menee helposti piiloon sääntöjen hävitessä. Tämä vaatisi uutta suhtautumista automaattiseen

toimintaan, jota on vaikea ennakoida. Tuollainen tapa toimia on toisaalta tuttu ihmisestä ja menetelmät löytyisivät vakiintuneista ohjaamoyhteistyön periaatteista. Sisäisen yhteistyön lisäksi tulee muistaa yhteistyö lennon muiden osapuolien, kuten lennonjohtajan ja maatoimintojen, kesken. Painopiste lentäjien ohjaamotyöskentelyssä tulee ilmeisesti siirtymään automatiikan käskyttämisestä valvontaan. Kuitenkin on todettava samoin kuin edellisessä luvussa, että yhden lentäjän valvontatehtäviin ei voida siirtyä, ellei automatiikka kykene varmasti itsenäiseen lentämiseen hätätilanteessa esimerkiksi varakentälle.

YHTEENVETO

Lentoyhtiöiden toiminta on perinteisesti tukeutunut vakiintuneisiin käytänteisiin ja muutokset ovat tapahtuneet huolellisen arvioinnin ja testauksen kautta. Koneoppiminen synnyttää joskus mustia laatikoita, joiden sisäisistä toiminnoista ei ole tarkkaa tietoa. Toinen vastakkainasettelu on lentotoiminnan tukeutuminen useisiin määräyksiin ja sääntöihin, kun taas koneoppiminen perustuu oppimiseen ilman sääntöjä. Koneoppimisessa annetaan tiedon kertoa, mutta toisaalta tekoäly voi perustua asiantuntijoiden kertoman tiedon avulla ohjattuun oppimiseen. Näiden kahden alueen yhdistäminen vaatii molempien osa-alueiden tuntemusta ja hyödyntämistä.

Tutkielmassa tarkasteltiin tutkimuksia, jotka liittyivät johdannossa perusteltuihin lentoyhtiön tärkeimpiin toimintoihin. Osa koneoppimisen hyödyntämisestä tapahtuu ilman tutkimuksia ja joitain mahdollisuuksia tulisi etsiä ja hakea muiden kuin lentoyhtiöiden toimintoihin liittyvistä tutkimuksista. Löydetyt tutkimukset antavat hyvät perusteet hyödyntämismahdollisuuksille ja tutkimustiedon käyttämiseksi omiin tarpeisiin.

Omien tarpeiden, asiantuntemuksen ja omien tietojen yhdistäminen antaa lentoyhtiölle mahdollisuuksia, joita muut eivät voi toteuttaa. Lippujen hinnoittelu on tästä hyvä esimerkki. Lentoyhtiön kannattaa käyttää hinnoittelussa koneoppimista omista tiedoista sekä saatavilla olevaa yleistä tietoa, kuten sosiaalista mediaa.

Myöhästymistietojen ennustaminen omiin tarpeisiin muokattuna perustuu myös saatavilla olevaan yleiseen ja omaan tietoon. Pelkkää myöhästymistä ei kannata ennustaa. Lentoyhtiön tulisi arvioida miten ja millaista tietoa kannattaa käyttää, jotta siitä olisi hyötyä ja sillä voitaisiin minimoida haittoja ja riskejä. Syyt ja seuraukset myöhästymiselle alkavat kaukaa ja tietoja voidaan täydentää ja hyödyntää vielä aivan viime minuuteilla. Koneoppimisella voisi kehittää menetelmän, joka ennustaisi ja seuraisi lähtevän ja saapuvan liikenteen virtaa ja auttaisi lentomiestä sekä lentoyhtiön toimintaa seuraavia yksiköitä optimoimaan kustannukset, päästöt sekä turvallisuuden. Mahdollisena tulevana tutkimuskohteenä olisi tulevan ja lähtevän liikenteen ennustaminen koneoppimisella. Saapuvan liikenteen ennustamisella saataisiin etuja lennonjohdolle, lentoyhtiölle, maa-toiminnoille sekä matkustajille. Parempi ennustettavuus lisäisi turvallisuutta ja sujuvuutta lentoliikenteeseen. Tuloajan ennustamisella voisi sekä vähentää päästöjä että polttoainekuluja. Lähtötietoina voisi käyttää aiempiin tutkimuksiin verrattuna asiantuntijoiden määrittelemiä ja esikäsiteltyjä tietoja, jotka mahdollistaisivat alueelliset piirteet.

Kolmas omiin tietoihin perustuva alue olisi lennontalentimien hyödyntäminen menetelmien ja lentoturvallisuuden parantamiseksi. Lentotietojen hyväksikäytön tutkimuksen voisi turvallisesti aloittaa simulaattorilennoilla ja hyödyntää koulutuksessa. Mukautuvan automaation tutkimuksiakin voi hyödyntää jo nyt simulaattorissa.

Miehistöjen ja automaation käyttö tulee varmasti muuttumaan tulevaisuudessa niin, että automaatio osallistuu enemmän miehistöyhteistyöhön. Toisen lentäjän korvaamiseen älykkäällä automaatiolla ei matkustajaliikenteessä siirrytä lähiaikoina, mutta automaation yhteistyön parantuessa lentoturvallisuutta saadaan parannettua. Koneoppimisen ratkaisuja kannatta tehdä tukemaan tehokasta ja turvallista toimintaa ja kulttuuria. Näitä ratkaisuja ei voida tehdä ilman lentoyhtiön tietovarastoja. Hyödyntäminen jää siten lentoyhtiön oman harkinnan varaan.

LÄHTEET

- Abdella, J. A., Zaki, N., Shuaib, K. & Khan, F. (2019). Airline ticket price and demand prediction: A survey. *Journal of King Saud University - Computer and Information Sciences*, 5, 6–7.
- Anbil, R., Tanga, R. & Johnson, E. L. (1992). A global approach to crew-pairing optimization. *IBM Systems Journal*, 31(1), 71–78.
- Baomar, H. & Bentley, P. J. (2016a). An intelligent autopilot system that learns piloting skills from human pilots by imitation. *Teoksessa Proceeding of International Conference on Unmanned Aircraft Systems (ICUAS)*, Arlington, VA USA. (1023–1031). London: University College London.
- Baomar, H. & Bentley, P. J. (2016b). An intelligent autopilot system that learns flight emergency procedures by imitating human pilots. *Teoksessa Proceeding of IEEE Symposium Series on Computational Intelligence (SSCI)*, Athens, Greece. (1–9). London: University College London.
- Baomar, H. & Bentley, P. J. (2017a). Autonomous navigation and landing of large jets using artificial neural networks and learning by imitation. *Teoksessa Proceeding of IEEE Symposium Series on Computational Intelligence (SSCI)*, Honolulu, HI, USA. (1–10). London: University College London.
- Baomar, H. & Bentley, P. J. (2017b). Autonomous landing and go-around of airliners under severe weather conditions using artificial neural networks. *Teoksessa Proceeding of Workshop on Research, Education and Development of Unmanned Aerial Systems (RED-UAS)*, Linköping, Sweden. (162–167). London: University College London.
- Bazargan, M. (2010). *Airline operations and scheduling* (2nd ed.). London, Englanti: Ashgate Publishing Limited.
- Bell, J. (2015). *Machine learning : Hands-on for developers and technical professionals*, Indianapolis, Indiana: Wiley. Haettu 13.3.2019 osoitteesta <https://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/detail.action?docID=1818248>
- Bergstra, J., & Bergio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13, 281–305.
- Blue1 Oy. (2014). *Operations manual part A* (65th ed.). Vantaa: Blue1 Oy.
- Cahill, J., Callari, T. C., Fortmann, F., Javaux, D. & Hasselberg, A. (2016). A-PiMod: A new approach to solving human factors problems with

automation. Teoksessa *Proceeding of Engineering Psychology and Cognitive Ergonomics*, (269–279). Cham: Springer International Publishing.

- Cahill, J., Callari, T. C., Fortmann, F., Suck, S., Javaux, D., Hasselberg, A., Sybert, H. S. & van Doorn, B. A. (2017). Adaptive automation and the third pilot: Managing teamwork and workload in an airline cockpit. Teoksessa *Proceeding of First International Symposium, H-WORKLOAD 2017*, (161–173). Dublin, Ireland: Dublin Institute of Technology.
- Campbell, N. (2003). Flight data Analysis—An airline perspective., 7. Haettu 4.2.2019 osoitteesta https://www.asasi.org/papers/2003/Flight%20Data%20Analysis_Campbell_V2.pdf
- Cao, Y., Pavelkova, A. & Behun, K. (2013). *Preliminary eye tracking / gesture algorithms*: A-PiMod consortium. Haettu 6.3.2019 osoitteesta <http://www.apimod.eu/Released/Newss/Deliverables.aspx>
- Cao, Y. & Benes, K. (2014). *Preliminary speech and dialect recognition algorithms*: A-PiMod consortium. Haettu 6.3.2019 osoitteesta <http://www.apimod.eu/Released/Newss/Deliverables.aspx>
- Chawla, N. V., Bowyer, K. W., Hall, L. O. & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357.
- Chen, C. H. & Chou, J. H. (2017). Multiobjective optimization of airline crew roster recovery problems under disruption conditions. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(1), 133–144.
- Choi, S., Kim, Y. J., Briceno, S. & Mavris, D. (2016). Prediction of weather-induced airline delays based on machine learning algorithms. Teoksessa *Proceeding of 2016 IEEE/AIAA 35th Digital Avionics Systems Conference (DASC)*, Sacramento, CA, USA: IEEE AESS.
- Constantinides, E. & Diercks, R. H. J. (2014). Airline price discrimination: A practice of yield management or customer profiling? Teoksessa *Proceeding of EMAC Conference*, (1–6). Enschede, Netherlands: University of Twente.
- Conversy, S., Chatty, S., Gaspard-Boulin, H., & Vinot, J. (2014). *The accident of flight AF447 rio-paris*. Friday, 17 October, 2014: Bureau d'Enquetes et d'Analyses France (BEA).
- Das, S., Matthews, B., Srivastava, A. & Oza, N. (2010). Multiple kernel learning for heterogeneous anomaly detection. Teoksessa *Proceeding of 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, (47–56). Washington, DC, USA: ACM.

- Davis, J. & Clark, A. (2011). Data preprocessing for anomaly based network intrusion detection: A review. *Computers & Security*, 30(6), 353–375.
- Deutsches Zentrum Fuer Luft - Und Raumfahrt Ev. (2016). *A-PIMOD report summary* (AAT.2013.3-1. - Human factors). Braunschweig Germany: Deutsches Zentrum Fuer Luft - Und Raumfahrt Ev.
- Deveci, M. & Demirel, N. C. (2015). Airline crew pairing problem: A literature review. *Teoksessa Proceeding of 11th International Scientific Conference on Economic and Social Development - Building Resilient Society*, (103–111). Varazdin, Croatia: Varazdin Development and Entrepreneurship Agency (VADEA).
- Directorate General for Mobility and Transport. (2011). *Flightpath 2050*. Luxemburg: Publications Office of the European Union.
- Estes, S., Helleberg, J., Long, K., Pollack, M. & Quezada, M. (2018). Guidelines for speech interactions between pilot and cognitive assistant. *Teoksessa Proceeding of 2018 Integrated Communications, Navigation, Surveillance Conference (ICNS)*, (10). Herndon, VA, USA: IEEE.
- Ferguson, J., Kara, A. Q., Hoffman, K. & Sherry, L. (2013). Estimating domestic US airline cost of delay based on european model. *Transportation Research Part C: Emerging Technologies*, 33, 311–323.
- Finnair. (2018). *Vuosikertomus 2017*. Helsinki-Vantaa: Finnair Oyj, 40.
- Flight Safety Foundation (2000). Safety Aspects of aircraft operations in crosswind. *Approach-and-Landing Accident Reduction Tool Kit*, 189–196. VA 22314, U.S.
- Gander, P. H., Rosekind, M. R. & Gregory, K. B. (1998). Flight crew fatigue VI: A synthesis. *Aviation, Space, and Environmental Medicine*, 69(9), 49–60.
- Glover, C., N. & Ball, M. O. (2013). Stochastic optimization models for ground delay program planning with equity–efficiency tradeoffs. *Transportation Research Part C: Emerging Technologies*, 33, 196–202.
- Harvey, C. (2016). *February 2016 on-time performance up from previous year, january 2016*. Washington: U.S Department of Transportation.
- Haykin, S. (2009). *Neural networks and learning machines, 3rd ed.* (3rd ed.). New Jersey, USA: Pearson Prentice Hall.
- Hoffman, K. & Padberg, M. (1993). *Solving airline crew scheduling problems by branch-and-cut*. Maryland, USA: The Institute for Operations Research and the Management Sciences.

- IBM (2019). Big Data & Analytics Hub: Social media Analytics. Haettu 25.2.2019 osoitteesta <https://www.ibmbigdatahub.com/analytics/social-media-analytics>
- IBM Watson (2019). Watson/Developer Resources/Documentation. Haettu 7.3.2019 osoitteesta <https://cloud.ibm.com/developer/watson/documentation>
- Jirgl, M., Boril, J. & Jalovecky, R. (2015). The identification possibilities of the measured parameters of an aircraft model and pilot behavior model on the flight simulator. Teoksessa *Proceeding of International Conference on Military Technologies (ICMT) 2015*, Brno, Czech Republic. (1–5). IEEE.
- Kaber, D. B. & Riley, J. M. (1999). Adaptive automation of a dynamic control task based on secondary task workload measurement. *International Journal of Cognitive Ergonomics*, 3(3), 169–187.
- Kaviyarasu, A., & Kumar, K. S. (2015). Simulation of flapping-wing unmanned aerial vehicle using X-plane and matlab/simulink. *Defence Science Journal* 64(4), 327–331.
- Khan, M. S. I., Tiasha, M. B. & Barman, S. (2017). Auto landing sequence for an unmanned aerial vehicle at a fixed point. Teoksessa *Proceeding of 2017 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, (175–180). Mirpur, Dhaka, Bangladesh: Department of Aeronautical Engineering, Military Institute of Science and Technology.
- Khmeleva, E., Hopgood, A. A., Tipi, L. & Shahidan, M. (2018). Fuzzy-logic controlled genetic algorithm for the rail-freight crew-scheduling problem. *KI - Künstliche Intelligenz*, 32(1), 61–75.
- Kim, Y. J., Choi, S., Briceno, S. & Mavris, D. (2016). A deep learning approach to flight delay prediction. Teoksessa *Proceeding of 2016 IEEE/AIAA 35th Digital Avionics Systems Conference (DASC)*, (1–6). Atlanta, Georgia, USA: Georgia Institute of Technology.
- Li, L., Das, S., Hansman, R., Palacios, R. & Srivastava, A. N. (2015). Analysis of flight data using clustering techniques for detecting abnormal operations. *Journal of Aerospace Information Systems*, 12(9), 587–598.
- Lufthansa Group. (2018). Annual report 2017. KG, Dillingen, Germany: Krüger Druck+Verlag GmbH & Co, 33.
- Ma, Q., Song, H. & Zhu, W. (2018). Low-carbon airline fleet assignment: A compromise approach. *Journal of Air Transport Management*, 68, 86–102.
- Maille, N. (2013). On the use of data-mining algorithms to improve FOQA tools for airlines. Teoksessa *Proceeding of 2013 IEEE Aerospace Conference*, (1–8).

- Maille, N. (2017). Modeling airline crew activity to improve flight safety analysis. *Teoksessa Proceeding of 2017 IEEE Aerospace Conference*, (1–11).
- Malighetti, P., Paleari, S. & Redondi, R. (2009). Pricing strategies of low-cost airlines: The ryanair case study. *Journal of Air Transport Management*, 15(4), 195–203.
- Manley, B. & Sherry, L. (2010). Analysis of performance and equity in ground delay programs. *Transportation Research Part C: Emerging Technologies*, 18(6), 910–920.
- Moreira, L., Dantas, C., Oliveira, L., Soares, J. & Ogasawara, E. (2018). On evaluating data preprocessing methods for machine learning models for flight delays. *Teoksessa Proceeding of 2018 International Joint Conference on Neural Networks (IJCNN)*, (1–8). Rio de Janeiro, Brazil: IEEE.
- Narangajavana, Y., Garrigos-Simon, F. J., García, J. S. & Forgas-Coll, S. (2014). Prices, prices and prices: A study in the airline sector. *Tourism Management*, 41, 28–42.
- Nelson, R. C. (1998). *Flight stability and automatic control*. (Vol. 2). WCB/McGraw Hill.
- Ng, A. Y. & Russell, S. (2000). Algorithms for inverse reinforcement learning. *Teoksessa Proceeding of In Proc. 17th International Conf. on Machine Learning*, (663–670). Berkeley, USA: Morgan Kaufmann.
- Oliveira, M. B. W. D. & Neto, A. D. A., (2013). Optimization of traffic lights timing based on multiple neural networks. *Teoksessa Proceeding of 2013 IEEE 25th International Conference on Tools with Artificial Intelligence*, Herndon, VA, USA. Federal University of Maranhão, UFMA.
- Pamplona, D. A., Weigang, L., Barros, A. G. D., Shiguemori, E. H. & Alves, C. J. P. (2018). Supervised neural network with multilevel input layers for predicting of air traffic delays. *Teoksessa Proceeding of 2018 International Joint Conference on Neural Networks (IJCNN)*.
- Phan, K. T., Maul, T. H. & Vu, T. T., (2015). A parallel circuit approach for improving the speed and generalization properties of neural networks. *Teoksessa Proceeding of 2015 11th International Conference on Natural Computation (ICNC)*, (1–7). Zhangjiajie, China: IEEE.
- Porter, M. E. (1985). *Competitive advantage: Creating and sustaining superior performance*. New York: Free Press.

- Salmon, P. M., Walker, G. H., & Stanton, N. A. (2016). Pilot error versus sociotechnical systems failure: A distributed situation awareness analysis of air france 447. *Theoretical Issues in Ergonomics Science*, 17(1), 64–79.
- Sammut, C. & Morales, E. F. (2004). Learning to fly by combining reinforcement learning with behavioural cloning. Teoksessa *Proceeding of Proceedings of the Twenty-First International Conference on Machine Learning*, New York, USA: ACM.
- Sherry, L. & Mauro, R. (2014). Controlled flight into stall (CFIS): Functional complexity failures and automation surprises. Teoksessa *Proceeding of 2014 Integrated Communications, Navigation and Surveillance Conference (ICNS)*, Herndon, VA, USA. (11). London: University College London.
- Smart, E., Brown, D. & Denman, J. (2012). A two-phase method of detecting abnormalities in aircraft flight data and ranking their impact on individual flights. *IEEE Transactions on Intelligent Transportation Systems*, 13(3), 1253–1265.
Haettu osoitteesta
<https://ieeexplore.ieee.org/xpl/RecentIssue.jsp?punumber=697>
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), (1929–1958). Toronto, Kanada. Toronto: University of Toronto.
- Stroeve, S., Van Doorn, A. & Cahill, J. (2016). A safety impact quantification approach for early stage innovative aviation concepts: Application to a third pilot adaptive automation concept. Teoksessa *Proceeding of 6th SESAR Innovation Days*, Delft, Netherlands: Technical University of Delft.
- Thiagarajan, B., Srinivasan, L., Sharma, A. V., Sreekanthan, D. & Vijayaraghavan, V. (2017). A machine learning approach for prediction of on-time performance of flights. Teoksessa *Proceeding of 2017 IEEE/AIAA 36th Digital Avionics Systems Conference (DASC)*, (1–6). St. Petersburg, FL, USA: IEEE.
- Turban, E., McLean, E. & Wetherbe, J. (2002). Information technology for management: Transforming business in the digital economy (3rd ed.). New York, USA: John Wiley & Sons, Inc.
- Wei, F., Amaya-Bower, L., Gates, A., Vasko, T. & Rose, D., (2016). The full-scale helicopter flight simulator design and fabrication at CCSU. Teoksessa *Proceeding of 57th AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*, San Diego, USA. New Britain, Connecticut: Central Connecticut State University.

- Weibo, L., Zidong, W., Xiaohui, L., Nianyin, Z., Yurong, L. & Fuad, A. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26.
- Zhang, Q., Ma, Y., Yang, Z. & Chen, Z. (2018). The civil aviation crew recovery time-space network model based on a tabu search algorithm. *Teoksessa Proceeding of Proceedings of 2017 Chinese Intelligent Systems Conference*, (373–382). Singapore: Springer Singapore.
- Yang, H. & Liu, X. (2018). Predictive simulation of airline passenger volume based on three models. *Teoksessa Proceeding of Data Science*, (350–358). Singapore: Springer Singapore.
- Young-Keun , & Cyungho L. (1995). Applications of neural networks in high-speed communication networks. *IEEE Communications Magazine*, 33(10), 68–74.
- Yuan, H., Xu, W. & Yang, C. (2014). A user behavior-based ticket sales prediction using data mining tools: An empirical study in an OTA company. *Teoksessa Proceeding of 2014 11th International Conference on Service Systems and Service Management (ICSSSM)*, (1–6).